

Tesis Doctoral
Ingeniería Energética

***Caracterización energética y desarrollo de
modelos predictivos en plantas de
cogeneración para la verificación de ahorros
en proyectos de eficiencia energética***

Autor: Francesco Rossi
Directores: Prof. Dr. David Velázquez Alonso
Prof. Dr. Íñigo Monedero Goicoechea

Departamento de Ingeniería Energética
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

2015



Tesis Doctoral
Ingeniería Energética

Caracterización energética y desarrollo de modelos
predictivos en plantas de cogeneración para la
verificación de ahorros en proyectos de eficiencia
energética

Autor:

Francesco Rossi

Directores:

Prof. Dr. David Velázquez Alonso

Prof. Dr. Íñigo Monedero Goicoechea

Departamento de Ingeniería Energética
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2015

Departamento de Ingeniería Energética
Escuela Técnica Superior de Ingenieros
Universidad de Sevilla

Tesis presentada por Francesco Rossi para la obtención del Grado de
Doctor Ingeniero Industrial

VºBº

Director de tesis

VºBº

Director de tesis

Doctorando

Prof. Dr. David
Velázquez Alonso

Prof. Dr. Íñigo
Monedero
Goicoechea

Francesco Rossi

Agradecimientos

En primer lugar quisiera expresar mi agradecimiento al profesor David Velázquez por su apoyo en el desarrollo de esta tesis, para lo cual agradezco haber tenido la suerte de poder contar con su gran experiencia en el campo de la eficiencia energética, así como con su iniciativa y soporte en todo momento de necesidad.

Asimismo agradecer al profesor Íñigo Monedero las valiosas aportaciones que han contribuido a mi formación en el campo de la minería de datos y de las técnicas de modelado predictivo.

Quisiera expresar un agradecimiento especial también al profesor Luis Pérez-Lombard que, con sus sabios consejos, ha contribuido al proceso de publicación de los artículos que se acompañan como parte integrante de este trabajo.

Resumen de tesis

En este trabajo se desarrolla una metodología para la cuantificación de los ahorros obtenidos de la implantación de medidas de mejora de la eficiencia energética en plantas industriales, con aplicación al caso concreto de una planta de cogeneración de ciclo combinado.

El estudio comienza con la revisión de la operación de la planta y de las funciones principales del sistema de control, junto con una evaluación de tipo cualitativo de los cambios acontecidos en la cogeneración tras la aplicación de las mejoras. Posteriormente se procede a la selección del volumen de control del análisis, con el objetivo de minimizar y dirigir los esfuerzos hacia las áreas del sistema efectivamente afectadas por las mejoras. Para la fase de modelado se propone la aplicación de la técnica de las redes neuronales artificiales, que se utilizan para reproducir las generaciones y consumos energéticos del sistema durante el período posterior al “retrofit” bajo su configuración anterior al “retrofit”, simulando el comportamiento de la planta en el caso en que los cambios no hubieran acontecido. Una parte relevante del análisis es dedicada a la selección de las variables a utilizar como predictores en la fase de modelado, así como a la determinación de la influencia relativa de dichas variables de entrada sobre los modelos finales. Por último se calculan los ahorros económicos, como diferencia entre el beneficio de explotación real y el beneficio que la planta generaría en el caso de no haberse implantado las mejoras (“línea base” del beneficio).

La aportación principal del estudio realizado reside en la demostración de la validez de una metodología basada en el modelado por redes neuronales artificiales para la cuantificación rigurosa de los ahorros procedentes de la aplicación de medidas de ahorro energético en plantas industriales. El trabajo deja vías abiertas de desarrollo, entre ellas:

- La definición de los aspectos técnicos a incluir entre las cláusulas contractuales necesarias para la implementación de la metodología propuesta en los contratos de rendimiento energético estipulados entre los clientes industriales y las empresas de servicios energéticos (ESE).
- La utilización de la técnica de modelado propuesta para la generación de líneas de referencia a emplearse para la detección en tiempo real de las desviaciones de la operación del sistema del comportamiento “estándar” o de referencia.
- El modelado por redes neuronales artificiales de procesos industriales de elevada complejidad y la utilización de los modelos obtenidos para la optimización de la operación mediante la aplicación del algoritmo genético.

Índice

Capítulo 1. Introducción.....	7
1. Marco en el cual se desarrolla el proyecto.....	8
2. La línea base de consumo energético	8
3. Las empresas de servicios energéticos y la problemática de la referencia de consumo	10
4. Modelado de la línea base de consumo en la industria. Estado del arte	11
5. Uso de las redes neuronales en plantas de potencia y otras aplicaciones especiales. Estado del arte	12
6. Motivaciones del proyecto	16
Capítulo 2. Objetivos y estructura del trabajo.....	19
1. Objetivos y alcance del trabajo	20
2. Estructura temporal del trabajo.....	21
3. Estructura documental del trabajo	22
Capítulo 3. Descripción de la planta de cogeneración.....	25
1. Configuración del sistema antes de las mejoras.....	26
2. Mejoras energéticas implantadas	29
Capítulo 4. Cuantificación de ahorros. Metodología propuesta	31
1. Fase 1. Estudio de la operación de la planta.....	32
1.1 TURBINA DE GAS.....	32
1.1.1 MODOS DE OPERACIÓN.....	32
1.1.2 FUNCIONES DEL SISTEMA DE CONTROL	34
1.2 CALDERA DE RECUPERACIÓN	36
1.2.1 MODOS DE OPERACIÓN.....	36
1.2.2 FUNCIONES DEL SISTEMA DE CONTROL	36
1.3 TURBINA DE VAPOR.....	36
1.3.1 MODO DE OPERACIÓN	36
1.3.2 FUNCIONES DEL SISTEMA DE CONTROL	36
2. Fase 2. Análisis del impacto de las medidas de ahorro energético (MAE).....	37
2.1 MAE 1. QUEMADORES DE BAJO NO _x EN LA CÁMARA DE COMBUSTIÓN DE LA TURBINA DE GAS.....	37
2.2 MAE 2. PRECALENTAMIENTO DEL AGUA DE ALIMENTACIÓN AL DESGASIFICADOR Y AMPLIACIÓN DEL ECONOMIZADOR DE LA CALDERA DE RECUPERACIÓN	39
3. Fase 3. Selección del volumen de control para el modelado	42
3.1 SELECCIÓN DE LOS EQUIPOS	42
3.2 SALIDAS DEL MODELO	42
3.3 ENTRADAS AL MODELO.....	43

3.4 DETERMINACIÓN DEL VOLUMEN DE CONTROL	44
4. Fase 4. Definición de los períodos de referencia.....	46
5. Fase 5. Selección y tratamiento de los datos.....	47
5.1 RECOGIDA DE DATOS	47
5.2 ELIMINACIÓN DE DATOS NO REPRESENTATIVOS	47
5.3 ELIMINACIÓN DE VARIABLES FUERA DEL ALCANCE DEL MODELADO	48
5.4 SELECCIÓN DE LAS VARIABLES OBJETO DE LA FASE DE MODELADO	48
5.5 ELIMINACIÓN DE DATOS ANÓMALOS Y NULOS	49
5.6 VARIABLES CALCULADAS	50
5.7 VARIABLES CONTENIDAS IMPLÍCITAMENTE EN DATOS MEDIDOS.....	50
5.8 RESULTADOS.....	50
5.8.1 SELECCIÓN DE VARIABLES.....	50
5.8.2 FILTRADO DE REGISTROS	55
6. Fase 6. Modelado.....	58
6.1 MODELADO CON REDES NEURONALES ARTIFICIALES. INTRODUCCIÓN	58
6.2 SELECCIÓN DE LAS VARIABLES DE INFLUENCIA.....	60
6.3 ENTRENAMIENTO DEL MODELO.....	64
6.3.1 ARQUITECTURA GENERAL DE LAS REDES NEURONALES	64
6.3.2 FUNCIONES DEL ALGORITMO DE ENTRENAMIENTO	64
6.4 SELECCIÓN DE LA ARQUITECTURA FINAL DE LAS REDES NEURONALES	68
6.5 DETERMINACIÓN DE LAS PRESTACIONES DEL MODELO	69
6.5.1 CRITERIO DE EVALUACIÓN	69
6.5.2 CAPACIDAD DE PREDICCIÓN DE LOS MODELOS RNA	70
6.6 MODELADO TERMODINÁMICO (OPCIONAL).....	83
6.6.1 DESCRIPCIÓN DEL MODELO.....	84
6.6.2 INTERFAZ DEL MODELO PARA SIMULACIONES MASIVAS	90
6.6.3 VALIDACIÓN DEL MODELO.....	96
7. Fase 7. Determinación de los ahorros	101
7.1 PREPARACIÓN DE LOS DATOS.....	101
7.2 DETERMINACIÓN DE LAS LÍNEAS BASE	105
7.3 VERIFICACIÓN DE AHORROS.....	105
Capítulo 5. Resultados y discusión	107
1. Líneas base de la planta.....	108
1.1 LÍNEAS BASE DE CONSUMO Y GENERACIÓN.....	108
1.2 LÍNEAS BASE DE OTROS PARÁMETROS DE INTERÉS.....	113
1.3 COMPARACIÓN CON EL MODELO DE SIMULACIÓN TERMODINÁMICA	114
2. Verificación de ahorros	118
Capítulo 6. Conclusiones.....	125

1. Aportaciones y aplicabilidad de la metodología propuesta	126
2. Fiabilidad y ventajas de los modelos RNA.....	127
3. Limitaciones.....	129
Capítulo 7. Desarrollos futuros y en curso	131
1. Avances y mejoras en la metodología propuesta	132
1.1 FEATURE SELECTION	132
1.2 FORGETTING FACTOR.....	133
1.3 AJUSTE DE LOS PORCENTAJES DE ENTRENAMIENTO	133
2. Aspectos ligados a la implantación de contratos ESE	134
3. Nuevas aplicaciones en curso	134
3.1 LÍNEAS BASE DE COMPORTAMIENTO ESPERADO DE LA COGENERACIÓN.....	135
3.2 MODELADO Y OPTIMIZACIÓN DE UNA PLANTA DE REFORMADO DE HIDRÓGENO...	141
Bibliografía	143
Abreviaciones y símbolos.....	151

***Capítulo 1.* Introducción**

1. Marco en el cual se desarrolla el proyecto

El trabajo propuesto, bajo el título “Caracterización energética y desarrollo de modelos predictivos en plantas de cogeneración para la verificación de ahorros en proyectos de eficiencia energética” ha sido desarrollado en el Departamento de Ingeniería Energética con sede en la Escuela Técnica Superior de Ingeniería de la Universidad de Sevilla, y la línea de investigación en la cual se enmarca el proyecto es la dedicada a ahorro y eficiencia energética en la industria. El proyecto propuesto ha sido realizado de acuerdo al marco regulatorio establecido por el Real Decreto 1393/2007, por el que se establece la ordenación de las enseñanzas universitarias oficiales y sucesivas modificaciones por el Real Decreto 99/2011, por el que se regulan las enseñanzas oficiales de doctorado. De acuerdo a los contenidos del RD 99/2011 (que sustituye el anterior Real Decreto en materia de enseñanzas de doctorado, ya que queda derogado el Capítulo V del RD 1393/2007), el autor se acoge, para la presentación del trabajo realizado, a la opción de “Tesis por compendio de publicaciones”, es decir, presenta para su evaluación como tesis doctoral un conjunto de trabajos publicados, conforme a lo establecido en el artículo 9 de la normativa reguladora del régimen de tesis doctoral (Acuerdo 9.1/CG 19-4-12).

El presente informe constituye un resumen extenso del trabajo realizado y contiene una introducción a las principales razones que motivan el proyecto, una descripción de la metodología desarrollada para el cumplimiento de los objetivos fijados y los resultados de la aplicación de dicha metodología al caso de una planta de cogeneración de ciclo combinado existente. Adicionalmente, puede hacerse referencia a los contenidos de las publicaciones anexas, que forman parte de la presentación del proyecto junto con este informe.

2. La línea base de consumo energético

El 20% del consumo de energía primaria de la Unión Europea (UE) está representado por el sector industrial y, aunque en el curso de las últimas dos décadas se haya logrado reducir un 30% el consumo energético específico, queda un alto potencial de mejora [1]. De acuerdo al objetivo UE de reducción en un 20% de los consumos energéticos y al plan estratégico UE para una economía y modelo energético bajo en carbono en 2050, la Comisión Europea (CE) fomenta el incremento de eficiencia en los procesos de generación, conversión y uso final de la energía [2,3]. En este sentido, es un deber de los estados miembros el desarrollo de nuevas estrategias específicas encaminadas a la reducción de los consumos en el sector industrial. En la misma línea, en el documento de referencia de la CE sobre las mejores tecnologías disponibles para la eficiencia energética se resalta la importancia de la implantación de sistemas de gestión energética y la realización de auditorías energéticas [4]. Otra medida prevista en este plan de eficiencia energética en la industria es la intensificación del uso de la

cogeneración de alta eficiencia, debido a las comprobadas características de fiabilidad y bajo impacto ambiental que ofrece esta tecnología.

Por estas razones, los estudios energéticos adquieren una importancia decisiva, tanto en los procesos industriales como en los sistemas e infraestructuras para el abastecimiento energético de los procesos industriales, incluidas las mismas plantas de cogeneración. Una vez que hayan sido implantadas las mejoras detectadas en el curso de las auditorías, un aspecto de especial interés es la determinación de los beneficios efectivamente conseguidos con dichas mejoras. Las estimaciones realizadas en la fase de estudio energético, como es natural, pueden presentar diferencias relevantes con respecto a los ahorros realmente obtenidos, entre otras razones la variación, en el curso de la operación del proceso, de las condiciones que habían sido asumidas como referencia para el estudio. Es una realidad que los ahorros procedentes de las mejoras de eficiencia no pueden medirse ya que, si por un lado es posible medir los nuevos consumos de energía tras la implantación de los cambios (configuración tras el “retrofit”), por el otro lado es imposible medir los consumos que caracterizarían el sistema en la actualidad en su configuración anterior a los cambios (antes del “retrofit”). A este segundo término se le suele llamar línea base de consumo energético.

La selección de los métodos a emplear para la determinación de la línea base de consumo energético es uno de los aspectos clave destacados en el protocolo internacional de referencia sobre medida y verificación de las prestaciones energéticas, el “International Performance Measurement and Verification Protocol” (IPMVP) [5]. Aun así, cabe destacar la carencia y por ello la necesidad de una formalización clara y rigurosa de metodologías específicas para la determinación de la línea base de consumo energético, tal y como se refleja en el interesante trabajo de Reichl & Kollmann [6]. Entre los varios métodos generales propuestos para este objetivo en el Programa Estatal de Energía y Clima de la Agencia de Protección Ambiental de Estados Unidos [7], se destaca por su practicidad el “método ingenieril”, que contempla la aplicación de fórmulas y correcciones estándares para el cálculo del consumo de energía antes del “retrofit”. Los resultados arrojados por este método, sin embargo, suelen estar caracterizados por altos niveles de error [8], lo cual hace inviable su aplicación sistemática en el campo industrial. Otros métodos propuestos en el mismo programa prevén la aplicación de análisis estadístico, si bien este término sea utilizado de forma muy general para referirse a modelos muy simplificados enfocados a aplicaciones en el sector terciario en su gran mayoría, y dirigidos a caracterizar los consumos antes y después del “retrofit” utilizando un número reducido de factores de influencia, entre otros las condiciones ambientales, el nivel de ocupación de los edificios y el número de horas de operación de las estructuras. Otros métodos previstos por el programa incluyen la simulación termodinámica de los sistemas objeto de estudio y, por últimos, se indica la posibilidad de utilizar los llamados “métodos integrativos”, es decir, combinaciones de los métodos previamente mencionados.

3. Las empresas de servicios energéticos y la problemática de la referencia de consumo

Un aspecto clave para la consecución de los objetivos de eficiencia energética a nivel europeo y mundial es la necesidad de garantizar la financiación de los proyectos de ahorro, y la verificabilidad de los ahorros es un factor fundamental en este sentido [1]. Una alternativa a las inversiones realizadas con capitales propios está constituida por los “contratos de rendimiento energético”, que contemplan acuerdos contractuales con empresas de servicios energéticos (ESE). De forma general, la ESE, una vez detectado un potencial de ahorro en las instalaciones del usuario consumidor de energía, se encarga de las inversiones económicas necesarias, ya sea con su propio capital o utilizando el financiamiento de intermediarios financieros. La ESE recupera el coste de inversión compartiendo una fracción de los ahorros económicos generados por la mejora, en una cuantía estipulada previamente en los acuerdos del contrato. Por su parte, el usuario ve garantizados los ahorros desde el comienzo de la operación una vez que las mejoras hayan sido implantadas.

La viabilidad y el carácter atractivo de los contratos de rendimiento energético han sido comprobados en varios países europeos, entre ellos Dinamarca, Francia y Alemania. No obstante, hasta ahora la gran mayoría de las aplicaciones han ido dirigidas principalmente al sector de la rehabilitación de edificios. Uno de los mayores obstáculos que impiden la difusión masiva de este tipo de contratos está representado por la falta de metodologías concretas y rigurosas que permitan determinar la línea base de consumo de energía y por lo tanto cuantificar los beneficios asociados a las mejoras de eficiencia. La eliminación de los obstáculos existentes para la difusión de los contratos de rendimiento energético y otros servicios de eficiencia se indica también como necesaria en la Directiva 2012/27/UE del Parlamento Europeo y del Consejo relativa a la eficiencia energética, para promover y fomentar la identificación de potenciales de ahorro y la sucesiva implementación de medidas de eficiencia. Asimismo, en el mismo documento se hace referencia a la necesidad de metodologías claras y transparentes para la verificación de los ahorros.

De acuerdo a estas observaciones, se puede concluir que la cuantificación de los ahorros procedentes de proyectos de mejora de la eficiencia energética en las instalaciones industriales no es un problema de fácil solución. Una de las razones principales de esta dificultad es la gran cantidad de variables que pueden influir en el consumo de energía de los procesos industriales, y las relaciones a menudo complejas y no lineales que intervienen en el comportamiento de dichos procesos. Es por lo tanto evidente la necesidad de métodos efectivos para la cuantificación de los ahorros energéticos y económicos, problemática que, como confirma el análisis bibliográfico efectuado y comentado en las secciones siguientes, está muy lejos de poderse considerar como resuelto.

4. Modelado de la línea base de consumo en la industria. Estado del arte

En esta sección se comentan los resultados de la revisión bibliográfica efectuada, enfocada a las aplicaciones existentes en cuantificación de ahorros en el sector industrial, que confirman la falta de exhaustividad actual en este campo y la necesidad de establecer metodologías rigurosas y concretas a ese respecto.

Kelly Kissock et al. [8] proponen un método simplificado para la verificación de los ahorros de energía basado en modelos de regresión lineal múltiple que permiten contabilizar los efectos de las variaciones en las condiciones ambientales y del volumen de producción acontecidas antes y después de la modernización de las instalaciones.

Dalglish et al. [9] generan una referencia de consumo a partir de datos medidos utilizando modelos de regresión lineal, para la determinación de los ahorros asociados a la mejora del sistema de control de motores eléctricos.

Otras metodologías más avanzadas han sido propuestas para la maximización de la eficiencia operativa de los procesos productivos industriales:

Velázquez et al. [10] modelan la línea objetivo de eficiencia aplicando una técnica de análisis discriminante basada en combinaciones lineales de variables de influencia y sucesiva modelización por regresión para la generación del consumo de referencia.

Motlaghi et al. [11] e Yanmin et al. [12] aplican la técnica de modelado por redes neuronales artificiales (RNA) para la caracterización del proceso de destilación en plantas de refino y utilizan el algoritmo genético (una útil herramienta para la determinación de puntos de óptimo en entornos complejos y no lineales) para la optimización del mismo. Una metodología similar es la aplicada por Nascimento et al. [13], para la modelización y optimización del proceso de producción de nylon y anhídrido acético. Otra aplicación similar está representada por el estudio de Liao et al. [14], que desarrollan un sistema experto basado en RNA para la predicción del comportamiento de una unidad de destilación y la maximización de la producción de la misma.

Otras aplicaciones de las RNA a los procesos industriales están representadas por los trabajos de Khayet et al. [15] y Chavan et al. [16], dirigidos a la predicción de las prestaciones de un proceso de desalación y gasificación de carbón en lecho fluido respectivamente.

Olanrewaju et al. [17] proponen un método híbrido para predecir el consumo de energía en el sector industrial a través de las RNA y la siguiente optimización en tiempo real del consumo mediante la aplicación del análisis envolvente de datos.

Monedero et al. [18] aplican la técnica de las RNA para modelar la operación histórica más eficiente en una planta industrial petroquímica y comparar el consumo energético actual con el modelo de referencia.

Aunque los ejemplos citados demuestran que la aplicación de la técnica RNA no es una novedad en el sector industrial, no se tiene constancia de aplicaciones relevantes de dicha técnica para el modelado de la línea base de consumo energético en aplicaciones industriales, entendida como el consumo del sistema antes de la implantación de medidas de mejora de la eficiencia energética. El análisis bibliográfico comentado en las secciones siguientes corrobora esta afirmación y permite generalizarla al sector de las plantas de producción de potencia.

5. Uso de las redes neuronales en plantas de potencia y otras aplicaciones especiales. Estado del arte

A continuación se resume el análisis bibliográfico llevado a cabo relativamente a las aplicaciones existentes de las RNA en el campo de las plantas de producción de potencia y otras aplicaciones especiales. Como resultado de la revisión bibliográfica efectuada, se destaca la falta de aplicaciones de esta técnica dirigidas a la cuantificación de los ahorros procedentes de la implementación de medidas de mejora energética.

La técnica RNA ha sido utilizada para el modelado de plantas de cogeneración en las siguientes aplicaciones:

- Modelado de las prestaciones y monitorización de las emisiones a la atmósfera de un sistema basado en micro turbina de gas [19].
- Desarrollo de sistemas de monitorización en tiempo real para ciclos combinados con interfaz gráfico para el usuario [20].
- Predicción de las prestaciones de una planta de turbina de gas y caldera de recuperación [21].
- Reproducción de las propiedades termodinámicas de vapor generado en la caldera de carbón de una central de cogeneración [22].
- Optimización de la distribución de las cargas eléctricas y térmicas de los componentes de una planta de cogeneración industrial [23].
- Ajuste de la generación de potencia al perfil de demanda del proceso [24].
- Modelado del comportamiento de un generador de vapor y de una turbina de vapor en una planta alimentada por biomasa y carbón [25].

El modelado con RNA ha sido aplicado a centrales de potencia de ciclo combinado para:

- Desarrollo de un sistema de monitorización para una planta que genera vapor a dos niveles de presión [26].
- Modelado de la eficiencia térmica del sistema y de las emisiones de NO_x , con comparación de los resultados obtenidos con modelos de mínimos cuadrados parciales. Los resultados muestran mayor capacidad por parte de las RNA para reproducir el comportamiento no lineal del sistema [27].

Otras aplicaciones de la metodología de modelado por RNA a centrales térmicas de producción de potencia incluyen:

- Predicción de la potencia generada en centrales alimentadas por carbón [28] y petróleo [29] y observación de la capacidad de predicción para operación fuera de los rangos de los datos utilizados para la generación de los modelos.
- Optimización del reparto de carga entre las unidades de generación de una planta de carbón [30] y definición de una estrategia para la desconexión parcial de carga con el objetivo de minimizar la carga desconectada y maximizar la estabilidad del sistema [31].
- Diagnóstico de fallos en el tren de precalentamiento del agua de alimentación de una unidad de potencia alimentada con carbón [32].
- Estimación de las emisiones de NO_x de sistemas alimentados con carbón [33], petróleo y metano [34], desarrollo de sensores artificiales para la monitorización de emisiones nocivas [35], modelización de emisiones y sucesiva validación del modelo a través de la comparación con los datos procedentes del sistemas de monitorización existente [36].
- Predicción de las prestaciones de equipos específicos como turbinas de vapor [37,38], calderas auxiliares de vapor [39] y condensadores [40].
- Evaluación de las capacidades predictivas para el modelado de la electricidad generada en una unidad de potencia alimentada con carbón y comparación con otros métodos estadísticos como modelos auto regresivos integrados de promedios móviles y regresiones lineales múltiples [41].

Algunas aplicaciones relevantes de metodologías híbridas que contemplan el uso de las RNA en conjunto con otras técnicas de modelado y algoritmos son:

- Modelos mixtos basados en RNA y algoritmo genético han sido aplicados para la optimización y la maximización de la eficiencia en:
 - ✓ Plantas de potencia de ciclo Rankine de vapor [42].
 - ✓ Sobrecalentadores de vapor en unidades de potencia alimentadas por combustibles fósiles [43].
 - ✓ Generador de vapor de carbón pulverizado [44].
 - ✓ Centrales térmicas supercríticas alimentadas con carbón [45].
 - ✓ Plantas de CO₂ supercrítico [46].
- Método híbrido basado en RNA y mínimos cuadrados parciales que se utiliza para predecir las emisiones de NO_x en los ciclos combinados [47].
- Metodología basada en el modelado de las prestaciones de una turbina de gas con RNA y sucesiva aplicación de la técnica de suma acumulativa para abordar el problema de la desviación entre modelo y datos medidos una vez transcurrido un tiempo de operación [48].

Numerosas aplicaciones de la técnica RNA han ido dirigidas al modelado de equipos específicos en plantas de potencia y procesos industriales, entre otros:

- Turbinas de gas, que es la unidad principal de potencia de la planta de cogeneración analizada en este trabajo. Las aplicaciones encontradas tienen especial enfoque en :
 - ✓ Reproducir la operación en condiciones de operación fuera de diseño, y comprobar el potencial de las RNA para la simulación de sistemas térmicos no lineales [49].
 - ✓ Incremento de la precisión de predicción de las prestaciones [50] y desarrollo de interfaces prácticos para el seguimiento de dichas prestaciones como función de las condiciones ambientales [51].
 - ✓ Monitorización de las prestaciones en términos de vibraciones y lubricación en motores marinos [52].
 - ✓ Supervisión del estado del equipo, como alternativa al mantenimiento programado convencional [53].
 - ✓ Optimización de la operación del compresor de la turbina [54].
 - ✓ Vigilancia del estado de funcionamiento en motores de aeronaves militares [55] y motores de turboeje para propulsión de helicópteros [56].
 - ✓ Inclusión de la técnica RNA como sustituto parcial para el modelado de algunos componentes de la turbina, y consecuente aumento de las capacidades de predicción con respecto a modelos puramente termodinámicos, hasta comprobar que los modelos mixtos resultantes (estadísticos y termodinámicos) son más idóneos para el empleo en sistemas de diagnóstico [57].
 - ✓ Determinación de herramientas de diagnóstico, que respondan a criterios de precisión y robustez frente a los errores en las mediciones [58] y que permitan detectar tanto fallos individuales de equipos como fallos combinados multicomponentes [59], así como malfuncionamientos de los sensores [60].
 - ✓ Aislamiento e identificación de fallos. En una primera aplicación [61] los autores comparan los resultados obtenidos por RNA con los del método lineal del filtro de Kalman, y es de destacar que, aunque ambas metodologías devuelvan resultados satisfactorios, las prestaciones del filtro de Kalman son ligeramente superiores, lo cual sugiere una mayor idoneidad de los modelos lineales para este tipo de aplicaciones. En una segunda aplicación [62] se analizan las prestaciones del modelo RNA en operación a carga parcial de la turbina y se observa que la precisión se ve algo reducida bajo esas condiciones.
 - ✓ Pronóstico de la vida útil por "creep" en las secciones calientes de la turbina [63].
 - ✓ Determinación de líneas de referencia aptas para reproducir los parámetros de eficiencia durante la operación normal, que permitan la detección de tendencias en los datos medidos y la identificación de desviaciones en el estado de funcionamiento de la turbina [64].
 - ✓ Mejora del control a través de la sustitución de los controladores proporcionales integrativos con controladores predictivos que emplean modelos RNA [65].
- Generadores de vapor, con generación de modelos dirigidos a:
 - ✓ Desarrollo de herramientas de monitorización en tiempo real a utilizar en sustitución de los modelos analíticos convencionales [66].

- ✓ Predecir las emisiones nocivas en calderas de carbón de parrilla móvil [67], calderas de carbón pulverizado [68] y calderas de lecho fluido circulante [69].
- ✓ Monitorizar la deposición de cenizas en plantas de potencia de carbón pulverizado [70,71].
- ✓ Reproducir el comportamiento [72] y los efectos del ensuciamiento sobre la eficiencia [73] en calderas de biomasa.
- Otros equipos. Las aplicaciones encontradas se refieren a :
 - ✓ Modelado y diagnóstico de hornos [74].
 - ✓ Predicción de la eficiencia en sistemas de bomba de calor en modo frío y caliente [75].
 - ✓ Modelado de las prestaciones de sistemas de refrigeración con ciclo de compresión mecánica de vapor alimentados por compresor a velocidad variable [76].
 - ✓ Predicción del comportamiento de torres de refrigeración [77] y condensadores evaporativos [78].
 - ✓ Modelado del mapa de prestaciones en compresores axiales [79] y predicción de las prestaciones termodinámicas en compresores tipo "scroll" [80].
 - ✓ Reproducción del comportamiento del proceso de secado en sistemas de lecho fluido [81,82].

Un sector que se distingue por el amplio aprovechamiento del potencial ofrecido por el modelado RNA es el de los motores de combustión interna, con aplicaciones para:

- Modelado de las prestaciones en motores de gasolina [83,84], metanol [85] y mezclas etanol-gasolina [86].
- Predicción [87] y control [88] de las emisiones.
- Determinación de los efectos de la utilización de biocombustibles sobre la eficiencia de motores diésel [89,90].

Otras aplicaciones especiales de la técnica de modelado RNA incluyen:

- Modelado, control [91] e identificación de accidentes programados [92] en plantas de potencia nucleares.
- Optimización de ciclos orgánicos de Rankine (ORC) [93] con aplicaciones a plantas geotérmicas basadas en el mismo ciclo [94].
- Reproducción del comportamiento de pilas de combustible del tipo de membrana polimérica [95], de óxidos sólidos [96] y de membrana de intercambio protónico [97].
- Predicción de las prestaciones de sistemas de refrigeración por absorción con eyecto-compresión alimentados con energía solar [98].
- Previsión de la velocidad del viento [99] y de la electricidad generada [100] en plantas eólicas, con aplicación del algoritmo competitivo imperialista (una estrategia de optimización inspirada en la evolución socio-política de los humanos y en la lógica del imperialismo) para la optimización del proceso de entrenamiento del modelo RNA [101].
- Mejora del control en generadores híbridos de electricidad diésel-eólicos [102].

- Predicción de las prestaciones [103] y maximización de la generación eléctrica [104] en sistemas fotovoltaicos y modelado de sistemas híbridos fotovoltaicos-diesel [105].
- Modelado de la potencia generada por instalaciones mareomotrices [106].
- Estimación de la bioelectricidad generada en pilas de combustible microbianas [107].
- Monitorización en tiempo real de la estabilidad de la tensión [108] y minimización de las desviaciones de voltaje [109] para la mejora de la gestión de los sistemas de generación y distribución de electricidad.
- Determinación de la eficiencia energética en sistemas de tracción por ruedas [110].

Por último, se destacan algunas aplicaciones en el sector edificatorio orientadas a:

- Predicción del consumo de combustible en sistemas de calefacción y acondicionamiento de aire en edificios públicos [111].
- Modelado de la demanda eléctrica en edificios bioclimáticos [112].
- Determinación del consumo de energía en el sector terciario (supermercados) y comparación de los consumos actuales con la referencia predicha por los modelos [113].

6. Motivaciones del proyecto

En las secciones anteriores ha sido introducida la problemática de la determinación de los ahorros, asunto de relevancia y de no inmediata solución ya que, como afirma de forma tan clara y directa Kromer [114], los ahorros “no existen” y por ello no pueden determinarse directamente, ya que haría falta un “medidor virtual” para cuantificar el consumo que acontecería en los sistemas energéticos en el caso en que no se hubieran implantado las mejoras de eficiencia energética.

De ello la necesidad de definir herramientas que permitan determinar la línea base de consumo energético (entendida como el consumo del sistema antes de los cambios), que supongan un nivel de precisión y rigor suficientes para su aplicación a los procesos industriales y plantas de potencia, y más extendidamente a los sistemas energéticos complejos, para los cuales se requieren técnicas de modelado capaces de captar las no linealidades que gobiernan el comportamiento de los mismos.

Como se ha comentado anteriormente, es de auspiciar que la estandarización de las herramientas para la generación de la línea base de consumo contribuya a la mayor afirmación y difusión a nivel europeo de los contratos de rendimiento energético con participación de empresas de tipo ESE. Del análisis bibliográfico efectuado relativo al modelado energético en campo industrial y de las plantas de potencia a través de técnicas estadísticas avanzadas, resulta evidente la falta de aplicaciones concretas dirigidas al modelado de la línea base de consumo para la verificación de ahorros. Es éste el tema hacia al cual va enfocado el presente trabajo, con el convencimiento del autor que los resultados obtenidos constituyen una ayuda concreta a la reducción de las

barreras que actualmente impiden el pleno desarrollo del mercado de los contratos de rendimiento energético.

Asimismo, se considera necesario - y es otro objetivo incluido en este trabajo - que una vez seleccionada y validada la técnica de modelado más idónea para la generación de la línea base de consumo, se proceda a incluir dicha herramienta en una metodología más amplia y general en la cual se esclarezcan todos los pasos a dar en el proceso de cuantificación de los ahorros, desde la captación y descarga de los datos medidos en el sistema hasta la obtención de los beneficios económicos procedentes de las mejoras energéticas implantadas.

***Capítulo 2.* Objetivos y estructura del trabajo**

1. Objetivos y alcance del trabajo

El objetivo de este trabajo es el desarrollo de una metodología para la determinación de los ahorros asociados a las medidas de mejora de la eficiencia en sistemas energéticos, que garantice unos niveles de precisión idóneos para su aplicación en el sector industrial. La metodología propuesta pretende proporcionar una herramienta válida para la cuantificación de la línea base de consumo de energía, que es el consumo actual virtual de energía del sistema en su configuración pasada, previa a los cambios acontecidos.

El trabajo incluye la definición de todas las fases que intervienen en el proceso de verificación de ahorros, incluida la recogida y tratamiento de datos operativos del sistema, la generación y la validación de los modelos empleados para la determinación de la línea de base de consumo y el empleo de dicha línea base para la cuantificación de los ahorros energéticos y económicos.

Para comprobar la validez de la metodología propuesta, se aplica a una planta de cogeneración existente para la cual se dispone de datos medidos de operación en un período que comprende la implantación de proyectos de mejora de la eficiencia energética. Para mejor caracterizar la metodología propuesta, se presentan los resultados específicos de la aplicación de cada una de las fases de la metodología, particularizados al caso concreto de la cogeneración. Es de destacar el elevado nivel de monitorización existente en este tipo de plantas, al tratarse de infraestructuras críticas para el suministro de energía (en forma eléctrica y térmica) a procesos industriales (proceso de refino de petróleo para el caso en cuestión). La presencia de plantas de cogeneración es frecuente en los emplazamientos industriales, ya que representan una solución eficiente y fiable para el suministro de electricidad y calor a procesos productivos consumidores intensivos de energía. De acuerdo con el objetivo de este trabajo, un sistema de cogeneración también puede ser considerado como una unidad industrial independiente, cuyos “productos” son la electricidad y calor, consumidos directamente en el proceso o exportados a terceros consumidores.

Una vez definidos los indicadores de consumo y producción energética de la planta, se procede a la generación de los modelos predictivos de los mismos, a partir de los datos históricos disponibles de la planta y mediante la aplicación de la técnica de modelado RNA. La elección de esta técnica se debe a su habilidad más que reconocida (y comprobada a través del análisis bibliográfico presentado anteriormente) para captar y reproducir los complejos patrones no lineales que rigen el comportamiento energético de los sistemas industriales.

Asimismo, se realizan simulaciones termodinámicas de la planta de cogeneración, que permiten comprobar los niveles alcanzables de exactitud y la efectiva aptitud de las RNA para la predicción del comportamiento del sistema, mediante la comparación y contrastación de los resultados obtenidos por ambas técnicas de modelado. Así que la primera metodología de modelado, las RNA, serán el foco de interés del proyecto

propuesto y la segunda un método de contrastación (cuya fiabilidad está ampliamente comprobada por la multitud de aplicaciones existentes) de la precisión de los resultados generados por la primera.

Por último se cuantifican los ahorros procedentes de la implantación de las medidas de eficiencia en la planta de cogeneración, a través de la comparación entre los datos medidos en el período post-implantación y las líneas base generadas a partir de los modelos predictivos.

El extenso conjunto de datos de operación de la planta almacenado en el sistema de monitorización existente se utiliza como base de todo el análisis, así como para la generación y sucesiva validación tanto de los modelos RNA como del modelo termodinámico de la planta.

2. Estructura temporal del trabajo

El presente trabajo es el fruto de 4 años de trabajo del autor. Aunque la adscripción del proyecto de tesis doctoral se produjera con fecha 07/03/2013, una parte relevante del proyecto fue desarrollada anteriormente a dicha fecha. A continuación se expone la estructura temporal del proyecto, en forma de una planificación “a posteriori”. Todas las fases del proyecto, comentadas de forma muy resumida en esta sección, son tratadas con más detalles en las secciones posteriores de este informe (capítulos 4 y 5). Las etapas que han constituido el estudio son las siguientes:

1. Desarrollo de una metodología para la medida y verificación de ahorros, basada en el modelado predictivo de índices de consumo y producción de energía frente a variables de influencia clave, para la determinación de líneas base de consumo y producción en proyectos de ahorro y eficiencia en plantas industriales. (Meses 1-6)
2. Tratamiento de los datos medidos obtenidos del sistema de control distribuido (SCD) de la planta de cogeneración: filtrado, eliminación de valores no válidos y/o fuera de rango y todas las operaciones de acondicionamiento necesarias para la creación de una base de datos idónea para su empleo en la fase sucesiva de modelado. (Meses 7-12)
3. Generación y validación de los modelos predictivos de los índices de consumo y producción, mediante aplicación de herramientas de minería de datos (RNA en concreto). Los modelos se generan a partir de los registros correspondientes al período anterior a la implantación de las medidas de ahorro en la planta. Un aspecto que cobra especial relevancia en esta fase es la optimización de la estructura interna de las RNA, llevada a cabo en fase de entrenamiento de los modelos para cada uno de los parámetros modelados. (Meses 13-23)
4. Determinación de la precisión de los modelos estadísticos obtenidos. Incluye la definición de los criterios para la cuantificación de los errores y la sucesiva determinación del error de ajuste de las salidas de los modelos frente a los datos

medidos. El error de ajuste se calcula para el período de validación de los modelos, que es el período para el cual se dispone de mediciones anteriores a la implantación de las medidas de eficiencia energética. (Meses 24-27)

5. Desarrollo de un modelo termodinámico de la planta a través de simulador. Incluye la calibración del modelo para el cuadro entre las salidas del modelo y las mediciones. (Meses 28-34)
6. Estimación de los errores cometidos por el modelo termodinámico. Se aplica al mismo período de validación de los modelos RNA, es decir, se valida el modelo en el período anterior a los cambios en la planta. (Mes 35)
7. Comparación de los resultados obtenidos con las dos técnicas de modelado empleadas (modelos RNA y simulación termodinámica), para comprobar la fiabilidad y precisión de los modelos obtenidos a partir de RNA. Incluye el proceso iterativo de calibración de los modelos en función del nivel máximo admitido de descuadre entre los errores de un tipo de modelo frente a otro. (Mes 36)
8. Generación de las líneas base de la planta, entendidas como los consumos y producciones del sistema en el período posterior a los cambios acontecidos pero bajo su configuración original anterior a dichos cambio. Se obtienen alimentando los modelos previamente generados con los registros (oportunamente filtrados) correspondientes a las variables de entrada a los modelos, medidas en el período posterior a la implantación de las medidas de ahorro. (Meses 37-40)
9. Cuantificación energética de los ahorros, a través de la comparación entre las líneas base obtenidas (modelos basados en redes neuronales) y las líneas de consumo real. Se aplica al período post-implantación de las medidas de ahorro. (Meses 41-46)
10. Determinación del beneficio económico asociado a la implantación de las medidas de ahorro energético en la planta. (Meses 47-48)

3. Estructura documental del trabajo

La documentación que compone la presentación de los resultados del trabajo propuesto incluye:

1. El presente informe, en el cual se resume el proyecto desarrollado, en términos tanto de metodología desarrollada como de resultados obtenidos. A pesar de tratarse de un resumen, ha sido intención del autor plasmar un documento completo que pueda servir de referencia para la comprensión de todos los aspectos del trabajo propuesto, independientemente de las publicaciones comentadas a continuación. El presente informe contiene de hecho gran parte de la información contenida en ambas publicaciones, relativa a metodología y resultados del proyecto, incluyendo aspectos y detalles para los cuales se podría, de otra forma, haber elegido la opción de remitir el lector a la consulta de dichas publicaciones.

2. Artículo aceptado para su publicación en revista de impacto en el sector de la energía y termodinámica.

- ✓ Autores del artículo: Francesco Rossi, David Velázquez Alonso
- ✓ Título del artículo: A methodology for energy savings verification in industry with application for a CHP plant
- ✓ Revista: Energy
- ✓ Fecha de aceptación para su publicación: 05 junio 2015
- ✓ DOI (identificador digital de objetos): 10.1016/j.energy.2015.06.016
- ✓ Índice de impacto de la revista para el año 2014: 4,844.

Calculado por el Instituto para la Información Científica (ISI o Institute for Scientific Information) y publicado en el informe de citas Journal Citation Reports.

- ✓ Ranking de la revista en sus categorías temáticas en base al índice de impacto (fuente: informe de citas Journal Citation Reports, 22/06/2015):

Nombre de la categoría	Número total de revistas en la categoría	Ranking de la revista en la categoría	Cuartil de la categoría
ENERGY & FUELS	88	12	1
THERMODYNAMICS	55	2	1

- ✓ Contenidos:

En el artículo se presenta la metodología desarrollada para la cuantificación de los ahorros procedentes de mejoras de la eficiencia energética, y se comentan los resultados de la aplicación de cada una de las fases contempladas en dicha metodología al caso concreto de una planta de cogeneración. De los dos artículos publicados éste es el más general, y el que mejor refleja la entidad del trabajo realizado en su globalidad. Sería aconsejable que la consulta de este artículo, que proporciona una visión completa de los aspectos energéticos y estadísticos involucrados en el estudio, se efectuara anteriormente al segundo artículo indicado a continuación, enfocado a temas más específicos de modelado y simulación.

3. Artículo publicado en revista de impacto del sector de la inteligencia artificial, informática e ingeniería.

- ✓ Autores del artículo: Francesco Rossi, David Velázquez Alonso, Íñigo Monedero Goicoechea, Félix Biscarri Triviño
- ✓ Título del artículo: Artificial neural networks and physical modeling for determination of baseline consumption of CHP plants
- ✓ Revista: Expert Systems with Applications
- ✓ Año/volumen/páginas: 2014;41:4658–69
- ✓ ISSN (número internacional normalizado de publicaciones seriadas): 0957-4174
- ✓ DOI (identificador digital de objetos): 10.1016/j.eswa.2014.02.001
- ✓ Índice de impacto de la revista para el año 2014: 2,240

Calculado por el Instituto para la Información Científica (ISI o Institute for Scientific Information) y publicado en el informe de citas Journal Citation Reports.

- ✓ Ranking de la revista en sus categorías temáticas en base al índice de impacto (fuente: informe de citas Journal Citation Reports, 22/06/2015):

Nombre de la categoría	Número total de revistas en la categoría	Ranking de la revista en la categoría	Cuartil de la categoría
COMPUTER SCIENCE, ARTIFICIAL INTELLIGENCE	123	29	1
ENGINEERING, ELECTRICAL & ELECTRONIC	249	48	1
OPERATIONS RESEARCH & MANAGEMENT SCIENCE	81	12	1

- ✓ Contenidos:

El artículo se centra sobre la determinación de las líneas base de consumo y producción energética de la planta de cogeneración. Este artículo puede considerarse una ampliación del primero, con especial enfoque a lo que concierne la fase de modelado del sistema. En concreto, se analizan los aspectos relacionados con la generación de los modelos predictivos a partir de datos medidos aplicando la técnica RNA, y se presentan los resultados en términos de capacidad de predicción y precisión de los modelos obtenidos. Asimismo, se comparan las líneas base obtenidas por RNA con las generadas por la vía más convencional y comprobada del modelado termodinámico, de forma que pueda contrastarse y comprobarse la validez de los modelos RNA.

***Capítulo 3.* Descripción de la planta de cogeneración**

1. Configuración del sistema antes de las mejoras

El sistema objeto del análisis es una planta de cogeneración existente de ciclo combinado, que suministra vapor a un emplazamiento industrial de refino de petróleo y genera aproximadamente 50 MW de potencia eléctrica a través de una turbina de gas (modelo GE 6551 B) y una turbina de vapor. La [figura 1](#) muestra el esquema del sistema, referido a la configuración original de la planta previa a la implantación de las medidas de mejora energética. Es una excepción el intercambiador de calor HX3, que corresponde a una de las medidas de ahorro acometidas, y se ha decidido incluirlo en el esquema para facilitar la comprensión de las secciones siguientes de este informe.

El combustible quemado es gas natural, tanto en la turbina de gas como en el quemador de post-combustión. La caldera de recuperación genera vapor vivo a la presión de 8.7 MPa, que es posteriormente expandido en una turbina de vapor de extracción/contrapresión. El suministro de vapor a la refinería se produce según contrato a dos niveles de presión:

- Media presión (MP), 2.2 MPa (presión de extracción)
- Baja presión (BP), 0.45 MPa (contrapresión)

Una parte del vapor de BP exportado a proceso procede del vapor de MP utilizado para el accionamiento de la turbobomba de agua de alimentación a caldera, y es enviado al colector de vapor de BP tras ser expandido en la turbina de accionamiento. Otra parte minoritaria está constituida por el vapor de flash de BP recuperado de la purga en la caldera de recuperación.

Los autoconsumos de vapor en la planta están representados por:

- Inyección de vapor de MP en la turbina de gas.
- Vapor de MP consumido para el accionamiento de la turbobomba.
- Vapor de BP para la alimentación del desgasificador.

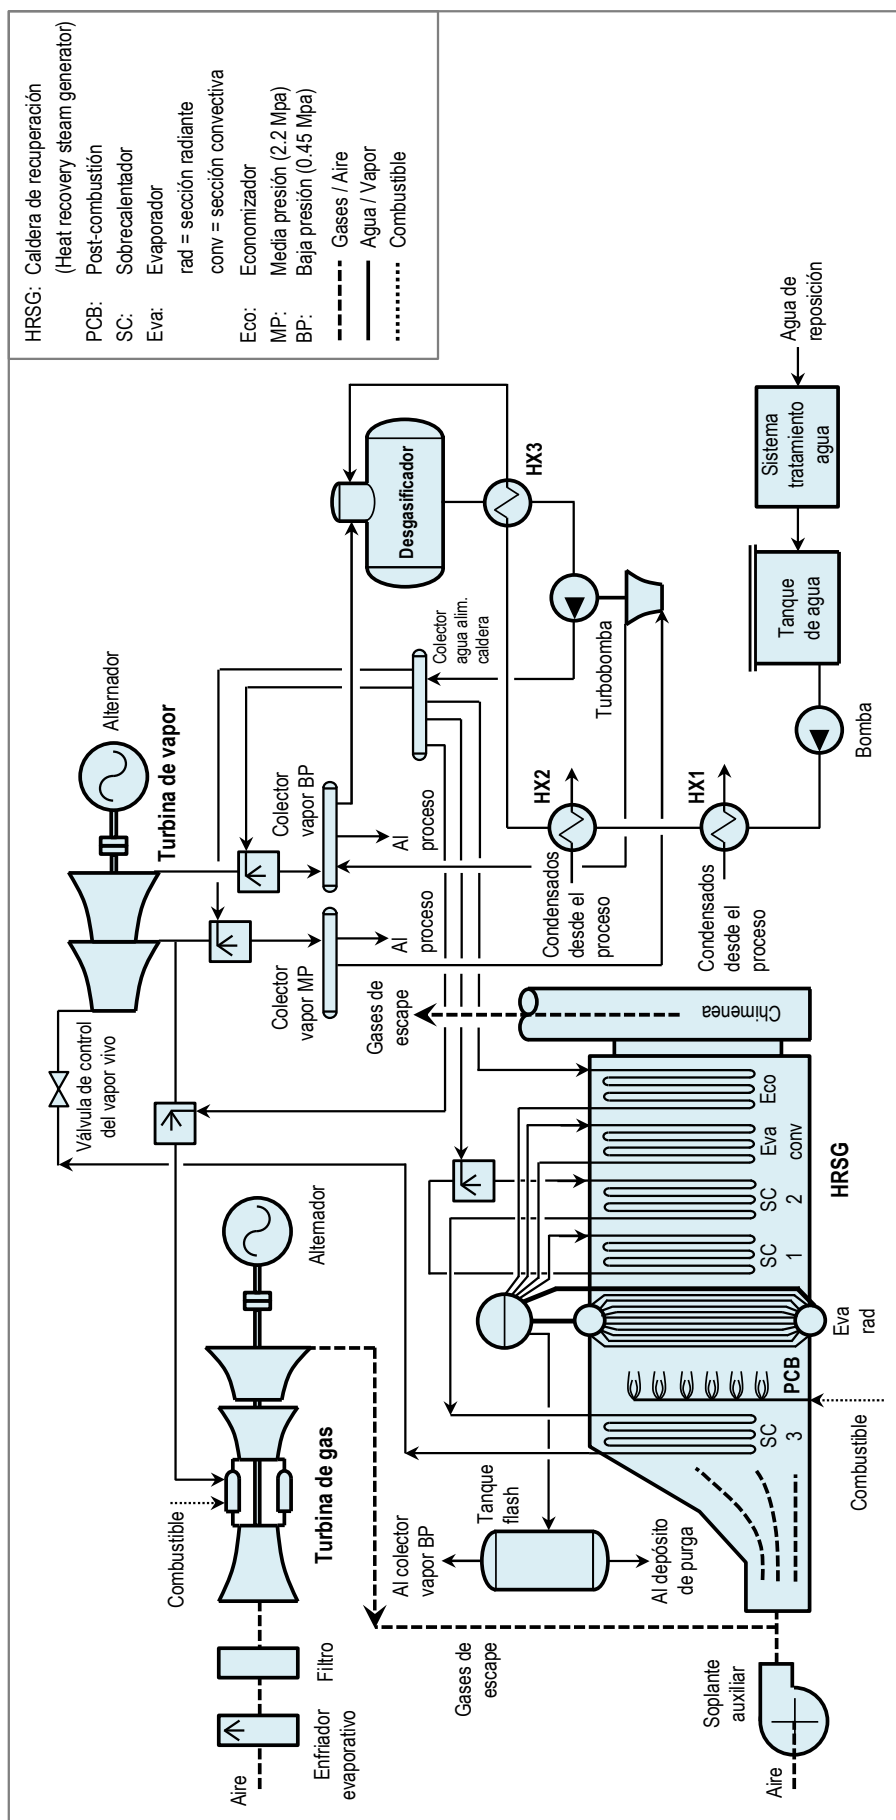


Figura 1. Esquema de la planta de cogeneración. Configuración original previa a la implementación de las mejoras.

En la [tabla 1](#) se resumen los datos relativos a los principales componentes del sistema.

Turbina de gas	
Potencia eléctrica nominal	38,0 MW
Heat rate nominal	11.378 kJ/kWh (PCI)
Temperatura gases de escape	542°C
Inyección de vapor (caudal máximo)	25 t/h
Caldera de recuperación (HRSG)	
Temperatura vapor vivo (operación)	480°C
Presión vapor vivo (operación)	8,7 MPa
Capacidad generación de vapor – carga base	135 t/h
Capacidad generación de vapor – carga punta	149 t/h
Turbina de vapor	
Potencia eléctrica nominal	15,0 MW
Presión vapor vivo (operación/máxima)	8,7/9,6 MPa
Temperatura vapor vivo (operación/máxima)	480/488°C
Caudal vapor vivo (operación/máximo)	135/155 t/h
Presión vapor de extracción (mínima/máxima)	1,9/2,4 MPa
Temperatura vapor de extracción (mínima/máxima)	295/320°C
Caudal vapor de extracción (operación)	113 t/h
Presión vapor de contrapresión (mínima/máxima)	0,20/0,66 MPa
Temperatura vapor de contrapresión (mínima/máxima)	175/275°C
Caudal vapor de contrapresión (operación)	22 t/h
Vapor exportado	
Vapor de MP – Presión (operación)	2,1 MPa
Vapor de MP – Temperatura tras atemperación (operación)	290°C
Vapor de BP – Presión (operación)	0,5 MPa
Vapor de BP – Temperatura tras atemperación (operación)	160°C

Tabla 1. Datos operativos de los principales equipos de la cogeneración.

Se destaca el exiguo valor del caudal de contrapresión con el cual opera la turbina de vapor, muy por debajo de los caudales por los cuales fue diseñada, lo cual conlleva un funcionamiento inadecuado del cuerpo de baja presión de la turbina, en el cual apenas se produce electricidad, reduciéndose su función prácticamente a laminar el vapor.

Los caudales de vapor de MP y BP exportados a proceso tienen valores muy cercanos a los de vapor de extracción y contrapresión de la turbina, siendo la diferencia constituida por los caudales de agua de atemperación necesarios para garantizar las temperaturas de consigna estipuladas por contrato indicadas en la tabla.

En la [tabla 2](#) se indican los consumos y generaciones de energía de la planta. Los datos en las tablas se refieren al año de operación 2007, previo a la implantación de las medidas de ahorro. Los valores porcentuales indicados para la exportación de vapor se

refieren a la masa total exportada, sin tener en cuenta los diferentes niveles entálpicos del vapor de MP y BP.

Generación eléctrica		
Turbina de gas	308.060 MWh/año	77,5%
Turbina de vapor	89.589 MWh/año	22,5%
Exportación de vapor a proceso		
Media presión	847.910 t/año	84,1%
Baja presión	160.457 t/año	15,9%
Consumo de combustible (gas natural)		
Turbina de gas	1.014.724 MWh _{PCI} /año	68,1%
Post-combustión	476.241 MWh _{PCI} /año	31,9%

Tabla 2. Consumos y generaciones de energía de la cogeneración (período previo a la implantación de las MAE).

2. Mejoras energéticas implantadas

En el período desde el 21 de abril 2008 hasta finales de agosto 2008 fueron acometidas en la planta las siguientes medidas de ahorro energético (en adelante MAE):

MAE 1. Quemadores de bajo NO_x en la cámara de combustión de la turbina de gas

La sustitución de los quemadores existentes fue principalmente justificada por los altos costes operativos asociados con el autoconsumo de vapor de MP representado por el vapor inyectado en la turbina de gas, utilizado para el cumplimiento de la reglamentación relativa a los límites de emisiones contaminantes a la atmósfera.

MAE 2. Precalentamiento del agua de alimentación al desgasificador y ampliación del área del economizador de la caldera de recuperación

Se instaló un nuevo intercambiador de calor (HX 3 en la [figura 1](#)) para la recuperación de parte del calor contenido en el agua de alimentación a la caldera de recuperación y el contemporáneo precalentamiento del agua a la entrada del desgasificador. Debido a la reducción de la temperatura del agua alimentada a la caldera, la MAE incluye la ampliación del área del economizador de la caldera. De esta forma se consiguió un mayor aprovechamiento del contenido entálpico de los gases de combustión en la caldera y una reducción consistente de la temperatura de los mismos a la salida de la chimenea, desde 190°C hasta 130°C aproximadamente.

En las secciones siguientes se detallan los efectos de ambas MAE sobre el consumo y generación de electricidad del sistema.

***Capítulo 4.* Cuantificación de ahorros.**
Metodología propuesta

En este capítulo, cuya estructura reproduce la del artículo “A methodology for energy savings verification in industry with application for a CHP plant”, se comenta la metodología desarrollada para la cuantificación de los ahorros procedentes de la implantación de las MAE y se caracteriza cada una de las fases de dicha metodología para el caso concreto de la planta de cogeneración descrita anteriormente.

1. Fase 1. Estudio de la operación de la planta

La primera fase del análisis se centra en el estudio y comprensión de los modos de operación y de la estrategia de control del sistema. Estos aspectos cobran especial relevancia para el desarrollo de las fases posteriores 3 y 5, en las cuales se procede a la selección del volumen de control para el modelado y el tratamiento y selección de los datos.

A continuación se resume la información más destacada relativa a los componentes principales de la planta de cogeneración.

1.1 Turbina de gas

1.1.1 Modos de operación

Los modos de operación de la turbina de gas son los siguientes:

- Plena carga (o carga base)

Es el modo normal de operación. Las prestaciones de la turbina (generación eléctrica, consumo de combustible, temperatura de los gases de escape) se ven afectadas por las condiciones ambientales (temperatura, humedad y presión atmosférica), por la pérdida de carga en la línea de aire de admisión al compresor y por la contrapresión al escape de la turbina.
- Carga parcial
 - ✓ Potencia fijada: La turbina de gas opera bajo un valor de potencia eléctrica fijado, variando el caudal de combustible alimentado y la apertura de los álabes de admisión del aire (VIGV - Variable Inlet Guide Vanes).
 - ✓ Apertura fijada de los VIGV: Se limita la admisión de aire fijando el ángulo de apertura de los VIGV. En este caso las prestaciones de la turbina presentan fluctuaciones acordes con las condiciones ambientales, de forma similar al funcionamiento a carga base. Este modo de operación se aplica en ocasión de las labores de limpieza “carbo-blasting” del compresor de la turbina, que consisten en inyección directa de sólidos con la turbina en funcionamiento. Este tipo de limpieza supone la reducción de la carga de la turbina fijando el ángulo de los VIGV a mínima apertura, que es de aproximadamente 56° para la turbina objeto del estudio.

Dichos modos de operación quedan reflejados en el histórico de registros de la planta, tal y como puede observarse en la [figura 2](#).




Figura 2. Modos de operación de la turbina de gas en el histórico de funcionamiento.

Atendiendo a la numeración de la figura y excluyendo los períodos de arranque y paradas de la planta, se distinguen claramente los distintos tipos de funcionamiento antes comentados:

1. Carga total: se ve que se trata de la operación habitual de la turbina de gas, tanto en el período previo como posterior a la implantación de las MAE.
2. Potencia fijada por rentabilidad de la operación:
 - ✓ En el mes de abril 2007 la turbina operó a carga reducida en horas nocturnas, con la potencia eléctrica generada fijada en valores próximos a 30 MW (numeración 2.a en figura).
 - ✓ La potencia máxima está limitada en 39,5 MW, lo cual supone funcionamiento a carga parcial de forma puntual durante los meses invernales. La razón de esta forma de operar reside en el límite de potencia eléctrica total que puede generar la planta, dado por la suma de las generaciones de la turbina de gas y de la turbina de vapor. De acuerdo al sistema retributivo en vigor en el período en cuestión para la electricidad generada por este tipo de plantas (establecido por el RD 661/2007, actualmente no en vigor), la electricidad total generada ha de mantenerse igual o inferior a 50 MW, para que sean máximos los incentivos concedidos sobre el precio de exportación a la red eléctrica (numeración 2.b en figura).
3. Bajadas de carga para limpiezas “carbo-blasting”: se trata de reducciones de carga periódicas, con frecuencia aproximada de diez días.

Otros tipos de limpieza de turbina de gas acontecidos en el histórico de registros son:

- Limpiezas “on-line”: no se pueden apreciar en el conjunto de datos mostrados, ya que se efectúan por pulverización directa del producto de limpieza sin alterar las condiciones nominales de funcionamiento de la turbina y con ello la disponibilidad de la planta. Se trata de un método de limpieza de eficacia limitada, que no permite la eliminación total de las pérdidas recuperables del compresor de la turbina.
- Limpiezas “off-line” (numeración 4 en figura): suponen la puesta fuera de servicio de la turbina de gas. Este método contempla varios ciclos de lavado por detergente seguidos de ciclos de enjuague, y termina con una etapa final de remojo. Entre los métodos de limpieza automáticos (de los que queda excluido el fregado a mano de los álabes del compresor), éste es el método más efectivo, aun llevando asociados los costes más altos en términos de lucro cesante.

1.1.2 Funciones del sistema de control

Las principales funciones del sistema de control de la turbina de gas son:

- Control de carga térmica

El sistema de control actúa sobre el caudal de combustible alimentado a la cámara de combustión, frente a los cambios del caudal másico de aire en la admisión causados por las variaciones de las condiciones ambientales (principalmente la temperatura), con el objetivo de mantener estable y máxima la potencia térmica contenida en los gases a la salida de la cámara de combustión (“carga térmica”). Ante una variación de la temperatura ambiente, la secuencia de acciones del lazo de control es la siguiente:

- ✓ Variación de la temperatura ambiente y con ello del caudal másico de aire a la admisión.
- ✓ Variación y medida, entre otros, de la temperatura de los gases de escape, presión de descarga del compresor y contrapresión escape.
- ✓ Cálculo de caudal másico de gases de escape, a partir de medidas de presión en la línea (no se dispone de detalles sobre la fórmula específica implementada para el cálculo).
- ✓ A partir de la temperatura de los gases de escape y el caudal de gases, se calcula la carga térmica, que es la variable controlada por el sistema.
- ✓ El sistema actúa sobre el caudal de combustible alimentado, que es la variable manipulada.

Esta forma de control conlleva variaciones de la temperatura de los gases de combustión a la entrada de la turbina (TET – Turbine Entry Temperature) ante variaciones de variables como la temperatura ambiente, por no ser una variable controlada. Asimismo, esta filosofía de control explica los incrementos significativos de la temperatura de escape en los momentos en los que la turbina opera en modo potencia fijada: para mantener la carga térmica, el sistema de control compensa la disminución del caudal de aire de admisión con un aumento de la TET, y con ella de la temperatura de los gases de escape.

- Control de la inyección de vapor

No existen lazos de control automático para el caudal de vapor inyectado en la cámara de combustión, sino que la regulación es manual y se efectúa de acuerdo a los niveles de emisión admitidos y medidos en la chimenea a la salida de la caldera de recuperación.

1.2 Caldera de recuperación

1.2.1 Modos de operación

Los modos de operación de la caldera de recuperación son los siguientes:

- Plena carga. Corresponde al modo de operación usual, en el cual se generan 135 t/h de vapor vivo utilizando el doble aporte de calor procedente de los gases de escape de la turbina de gas y del quemador de post-combustión.
- Potencia pico. En situaciones excepcionales y para períodos no prolongados, la generación de vapor vivo puede ser aumentada hasta 149 t/h, a través del incremento de aporte de combustible al quemador de post-combustión.
- Modo independiente. Aplica durante las paradas de la turbina de gas. Se activa el ventilador para la operación de la caldera de recuperación en modo aire ambiente, siendo la post-combustión el único punto de consumo de combustible para la generación del vapor vivo generado.

1.2.2 Funciones del sistema de control

Las principales funciones del sistema de control de la caldera son:

- Actuación sobre el caudal de combustible quemado en la post-combustión para regular la generación de vapor vivo, de forma que sean constantemente compensadas las fluctuaciones de la presión del vapor inducidas por cambios de carga en la turbina de vapor.
- Variación del caudal de agua impulsado por la bomba de alimentación de la caldera, para mantener el nivel de agua en el calderín.
- Inyección de agua para atemperación y mantenimiento del set point de temperatura de consigna del vapor vivo.

1.3 Turbina de vapor

1.3.1 Modo de operación

La estrategia de control de la turbina de vapor está inspirada en el criterio de maximización de la generación de electricidad, que se consigue aumentando el caudal de vapor expandido en el cuerpo de BP de la turbina, compatiblemente con la demanda de vapor de MP de la refinería.

1.3.2 Funciones del sistema de control

Los lazos de control empleados para conseguir el objetivo antes comentado son dos:

- La carga de la turbina se controla fijando un set point del caudal de vapor vivo, mantenido a través de la actuación sobre la válvula de estrangulamiento a la entrada de la turbina de vapor. La modulación de la apertura de la válvula induce variaciones de la presión en la línea del vapor que, a su vez, activan el lazo de control de presión de la caldera de recuperación.
- La extracción de vapor de MP es controlada a través de la actuación sobre la válvula de conexión entre los cuerpos de alta y baja presión de la turbina. La señal de entrada para la regulación está representada por la presión en el colector de vapor de MP, directamente relacionada con el caudal de vapor consumido por el proceso.

2. Fase 2. Análisis del impacto de las medidas de ahorro energético (MAE)

Con el objetivo de definir los parámetros energéticos a incluir en el análisis y definir cuáles son las salidas a generar por los modelos (hágase referencia a la [fase 3.2](#) de la metodología), se precisa realizar una evaluación cualitativa de los efectos de las MAE implantadas sobre el consumo y producción de energía del sistema, que permita esclarecer tanto las repercusiones positivas como los impactos negativos que afectan al beneficio de explotación de la planta.

2.1 MAE 1. Quemadores de bajo NO_x en la cámara de combustión de la turbina de gas

Los efectos principales sobre la operación de la planta de cogeneración fueron los siguientes:

- El cese de la inyección de vapor en la cámara de combustión de la turbina de gas, que causó:
 - ✓ Reducción de la electricidad generada por la turbina de gas.
 - ✓ Disminución del consumo de combustible de la turbina de gas.
 - ✓ Aumento del vapor de MP exportado a refinería, correspondientemente a la eliminación del consumo de vapor de inyección.
 - ✓ Incremento del consumo de combustible en el quemador de post-combustión, debido a la disminución de la potencia térmica contenida en los gases de escape de la turbina de gas.

Como se comenta más adelante, el tercer efecto (aumento de exportación de vapor de MP) determinó un incremento del incentivo económico sobre la electricidad exportada a la red, que compensa el balance económico negativo resultante de los primeros dos efectos.

- El cese de las limpiezas on-line del compresor de la turbina del tipo “carbo-blasting”, debido a que los nuevos quemadores no toleran la inyección de materiales sólidos en el compresor. Por esta razón se suprimieron las bajadas de carga periódicas de la turbina de gas, con consecuente aumento de la electricidad producida.
- Como consecuencia del cese de la limpieza “carbo-blasting”, se instaló un segundo filtro en la línea del aire a la entrada del compresor, para evitar el excesivo ensuciamiento de la turbina. Las pérdidas de carga introducidas con esta medida determinaron una disminución de la electricidad generada y del combustible quemado en la turbina de gas.

En las [figuras 3 y 4](#) se muestran algunos de los efectos comentados: la eliminación de las bajadas de carga de la turbina de gas y el aumento de la pérdida de carga en la línea del aire a la entrada del compresor de la turbina.




Figura 3. Efectos de MAE 1: cese de las bajadas de carga de la turbina de gas.




Figura 4. Efectos de MAE 1: aumento de la pérdida de carga del aire de admisión a la turbina.

2.2 MAE 2. Precalentamiento del agua de alimentación al desgasificador y ampliación del economizador de la caldera de recuperación

Las repercusiones de la medida de eficiencia fueron las siguientes:

- Un descenso del consumo de vapor de BP en el desgasificador, con consecuente aumento del ratio entre exportación de vapor de BP y generación de vapor vivo.
- El incremento del caudal de agua tratada de alimentación al desgasificador.
- La reducción de la temperatura de chimenea de los gases de la caldera de recuperación, como efecto del enfriamiento del agua de alimentación a la caldera.

Los diagramas en las [figura 5-8](#) muestran los efectos comentados.




Figura 5. Efectos de MAE 2: reducción del consumo de vapor de BP en el desgasificador.




Figura 6. Efectos de MAE 2: incremento del caudal de agua tratada alimentado al desgasificador.




Figura 7. Efectos de MAE 2: disminución de la temperatura del agua de alimentación a la caldera de recuperación.




Figura 8. Efectos de MAE 2: disminución de la temperatura de los gases en chimenea de la caldera de recuperación.

3. Fase 3. Selección del volumen de control para el modelado

Se procede a la definición de las áreas y a la selección de los equipos del sistema a incluir en la fase posterior de modelado ([fase 6](#)). La determinación del volumen de control y de las entradas y salidas de los modelos se efectúa atendiendo a los criterios indicados a continuación.

3.1 Selección de los equipos

De acuerdo a los objetivos de la metodología propuesta, se excluyen del volumen de control de modelado las áreas y equipos que no se ven afectados por las MAE.

Para el caso de la cogeneración objeto del análisis, no se precisa el modelado de la turbina de vapor, ya que su operación quedó inalterada tras la implantación de las MAE. De hecho, la generación de electricidad de la turbina es fijada por las condiciones (caudal másico, temperatura y presión) del vapor vivo a la entrada y del vapor de extracción. La producción y las condiciones de temperatura y presión del vapor vivo son constantemente controladas a través de los sistemas de regulación del combustible alimentado al quemador de post-combustión y del caudal de agua de alimentación a la caldera de recuperación. Por esta razón los cambios introducidos por las MAE en las condiciones de los gases de escape de la turbina de gas no tienen repercusiones sobre las propiedades del vapor a la entrada de la turbina de vapor. Por otro lado, la cantidad de vapor extraído de la turbina depende únicamente de la demanda de vapor de MP y BP en el proceso. Como se ha comentado anteriormente, uno de los efectos de las MAE fue la disminución de los autoconsumos de vapor de la cogeneración, lo cual determinó un aumento del vapor de MP y BP exportados a proceso. En un escenario en la cual el proceso no hubiera tenido la capacidad suficiente para absorber estos aumentos, el cambio habría implicado la modificación de la estrategia de control de la extracción de vapor en la turbina. Sin embargo no se registraron excesos de vapor (venteos), ya que el aumento de exportación fue compensado con la reducción de carga de otros equipos auxiliares que abastecen vapor al proceso. Por estas razones la operación de la turbina de vapor no sufrió cambios, y queda confirmada la independencia entre la electricidad generada en la turbina y la implantación de las MAE.

3.2 Salidas del modelo

Para definir las salidas del modelo, merece recordar el objetivo del modelado, que es reproducir el consumo y producción de energía del sistema en el período posterior a la implantación de las MAE suponiendo que las MAE no hubieran sido implantadas. Atendiendo a esta premisa, se tienen que determinar todos los parámetros de

producción y consumo de energía afectados por las MAE, que serán las salidas de los modelos a generar. En este sentido, se considere la importancia de la [fase 2](#) previamente desarrollada: en la [tabla 3](#) se resumen las repercusiones de las MAE sobre el sistema y se indican los parámetros a modelar para la comparación energética de la planta de cogeneración antes y después de las modificaciones.

Medidas de ahorro energético implantadas (MAE)		MAE 1. <i>Quemadores de bajo NO_x en la cámara de combustión de la turbina de gas</i>			MAE 2. <i>Precalentamiento agua de alimentación desgasificador y ampliación área economizador de la HRSG</i>	
Consecuencias directas de las MAE		<i>Cese de la inyección de vapor en TG</i>	<i>Instalación de un nuevo filtro del aire TG</i>	<i>Cese de las bajadas de carga periódicas de la TG</i>	<i>Incremento del área del economizador en la HRSG</i>	<i>Reducción del consumo de vapor de BP en el desgasificador</i>
Efecto sobre los parámetros de consumo y producción del sistema	<i>Potencia eléctrica TG</i>	Reducción	Reducción	Aumento*	Reducción	-
	<i>Consumo de combustible TG</i>	Reducción	Reducción	Aumento*	Reducción	-
	<i>Consumo de combustible post-combustión</i>	Aumento**	Aumento**	Reducción*	Aumento**	-
	<i>Inyección vapor MP en TG</i>	Eliminado	-	-	-	-
	<i>Consumo vapor BP en desgasificador</i>	-	-	-	-	Reducción
<p>* Efecto no frecuente y de carácter no continuado</p> <p>** Efecto debido a la reducción de la potencia térmica contenida en los gases de escape de la TG</p>						

Tabla 3. Salidas del modelo y efectos principales de las MAE implantadas.

3.3 Entradas al modelo

En esta fase se efectúa una selección previa de las variables que son potenciales candidatas a ser utilizadas como entradas (input) para los modelos que se quieren desarrollar. Basándose en el conocimiento físico del sistema, se deben incluir todas aquellas variables que puedan tener influencia sobre las salidas del modelo previamente definidas ([fase 3.2](#)), independientemente de cuál sea la magnitud de su efecto. Se destaca el carácter preliminar de esta selección, lo cual supone que se incluyan también las variables sobre las cuales no se tiene total certidumbre de que su impacto sea significativo. El conjunto preliminar de variables obtenidos será procesado posteriormente en la fase de modelado, en la cual se procede a la selección definitiva de los inputs más representativos ([fase 6.2](#)).

En línea general, entre las entradas al sistema se seleccionarán aquellas que cumplan los requisitos de ser variables independientes y de no haber sido directamente afectadas por las MAE implantadas. La segunda condición responde a la función de los modelos que se quieren generar, que es predecir el comportamiento del sistema en su configuración previa al retrofit bajo las condiciones y valores de set point actuales (período post-retrofit), una vez que haya sido averiguado que dichas condiciones no han sufrido cambios por efecto de las MAE.

Las entradas al sistema son de dos tipos:

- Variables controlables
 - Incluyen los set points utilizados en el sistema de control, que para la planta de la cogeneración son:
 - a. Caudal másico y temperatura del vapor vivo.
 - b. Nivel de emisiones de NO_x .
- Variables no controlables, que para la planta de la cogeneración son:
 - a. Condiciones ambientales.
 - b. Propiedades del combustible (poder calorífico, densidad, temperatura, presión).
 - c. Otros parámetros operativos que tiene influencia sobre las salidas seleccionadas (indicados en la [figura 9](#)).

3.4 Determinación del volumen de control

Una vez finalizadas las fases anteriores, es posible proceder a la determinación del volumen de control definitivo, que se muestra en la [figura 9](#) junto con las variables de entrada y salida seleccionadas.

Sin el objetivo de detallar todas las consideraciones físicas que han llevado a la selección del conjunto preliminar de las posibles variables de entrada a los modelos, cabe incluir una observación relativa a la producción de vapor vivo en la caldera de recuperación, que resalta la importancia de la [fase 1](#) del análisis (estudio de la operación de la planta):

Aunque las exportaciones de vapor de MP y BP al proceso incrementaran por efecto de la reducción del autoconsumo de vapor de la planta, la producción de vapor vivo en caldera de recuperación y la extracción de vapor de la turbina no se vieron afectados por la implantación de las MAE. No obstante, en otro escenario el aumento de generación de vapor de la cogeneración podría haber excedido la demanda del complejo y no haber sido absorbido completamente por el proceso, dándose situaciones de exceso y venteo de vapor. En ese caso no podría haberse seleccionado el caudal másico de vapor vivo como variable de entrada a los modelos, sino que habría sido necesario estudiar la dependencia de dicho caudal de la demanda de vapor, lo cual requeriría un análisis adicional de la operación de la red de vapor del complejo.

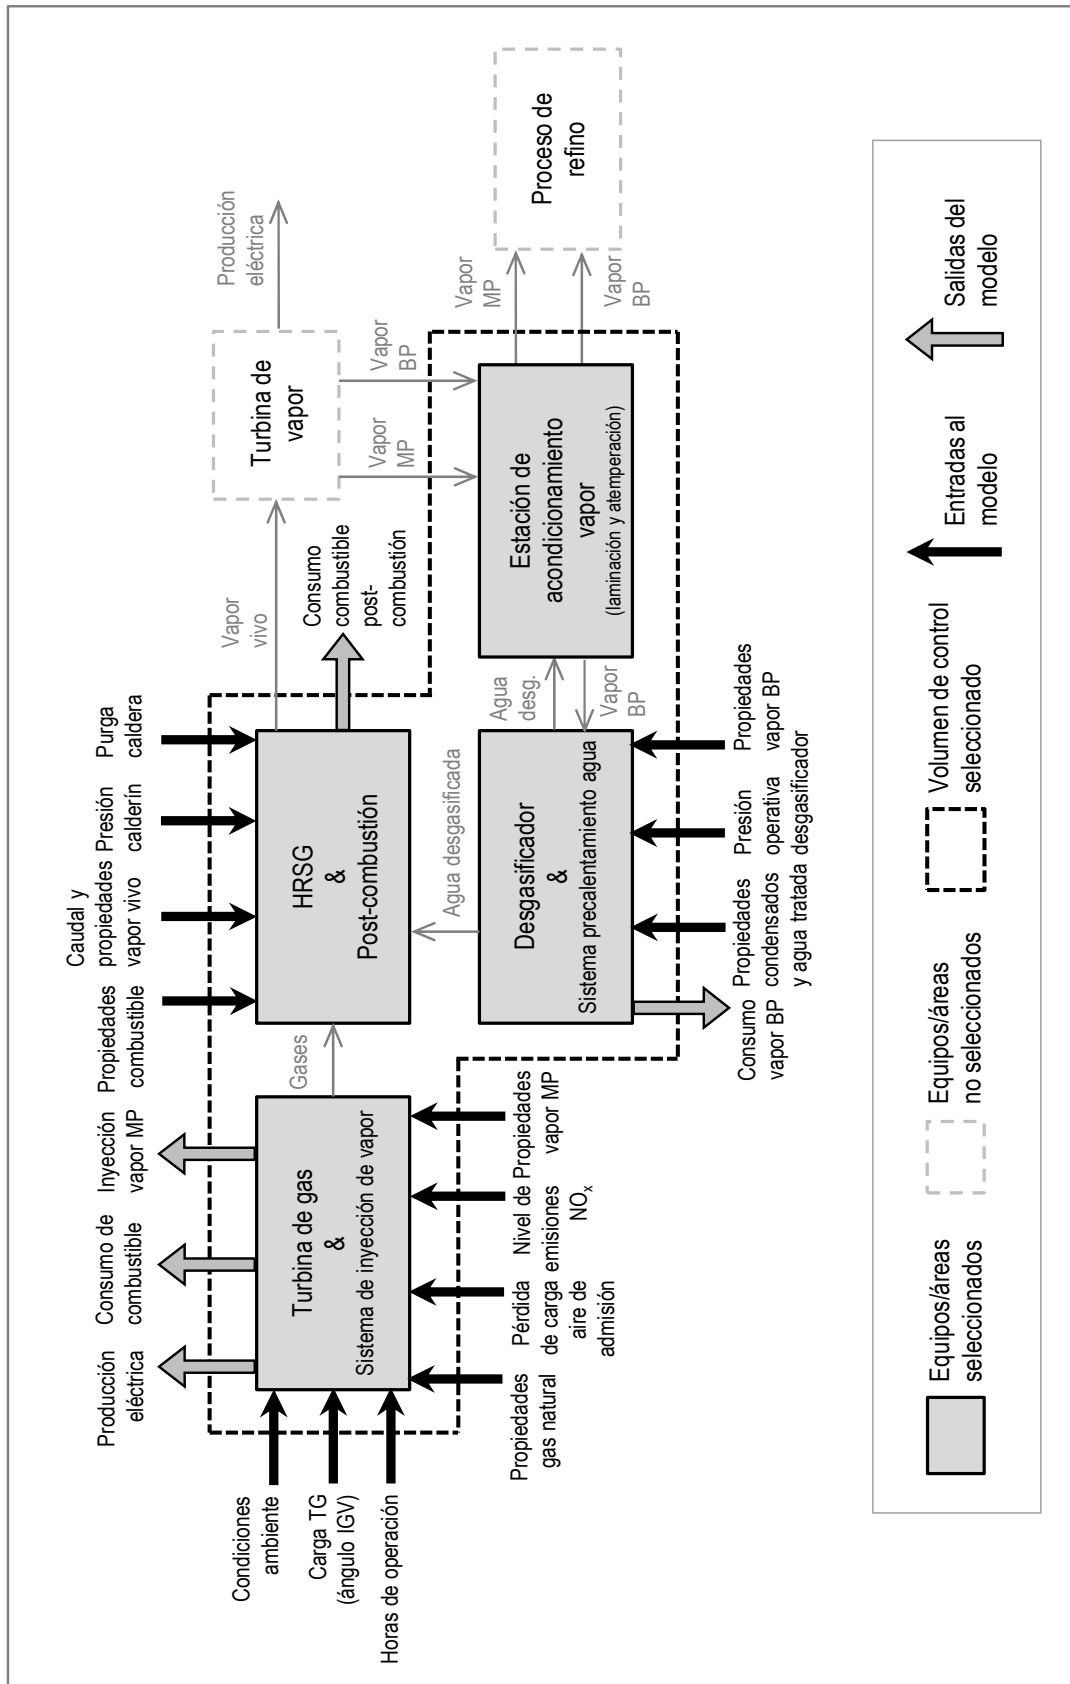


Figura 9. Volumen de control seleccionado y entradas/salidas para el modelado de la cogeneración.

4. Fase 4. Definición de los períodos de referencia

Es necesario determinar los períodos de referencia a utilizar para el modelado y para la verificación de los ahorros. Para ello es suficiente definir una fecha de inicio para el período de modelado y una fecha final para el período de verificación (o "período de referencia"), ya que la parada de la planta para la implementación de las MAE representa la transición de un período a otro. Asimismo, se deben identificar los cambios más significativos en el sistema que acontecieron en los períodos pre-y post-retrofit, y que puedan afectar negativamente al desarrollo de los modelos y/o a su utilización.

A continuación se indican las principales modificaciones acometidas en la planta que no son objeto de la verificación de ahorros:

- Revamp de la turbina de vapor. En septiembre 2006 la turbina sufrió una modificación sustancial que modificó su diagrama característico de funcionamiento y se implantó el nuevo sistema de control cuyas funciones han sido comentadas anteriormente. Las modificaciones se finalizaron el 16 febrero 2007.
- Modificación en la operación de la caldera de recuperación. El 6 mayo 2009 se cambió el modo de operación de la caldera a potencia pico de forma continua.

Período de modelado

Por las razones antes comentadas se elige el 16 febrero 2007 como fecha de comienzo del período de modelado, que coincide con la finalización de una modificación sustancial en la planta de cogeneración. El modelado de la planta antes de este período no sería de mucha utilidad, ya que los modelos generados estarían reproduciendo el comportamiento de un sistema distinto del que se quiere utilizar como referencia para la determinación de los ahorros. La fecha final del período de modelado es el 21 abril 2008, que es el momento en el cual comenzó la implantación de las MAE en la cogeneración.

Período de verificación de ahorros

Suponiendo la aplicación de la metodología propuesta en un programa de medida y verificación de las prestaciones energéticas, la selección del período de referencia para la cuantificación de ahorros debería acordarse entre las dos partes, la ESE y el cliente, y deberían incluirse todas las cláusulas que regulen las situaciones en las cuales se producen nuevos cambios en este período.

Para el caso propuesto en este trabajo, obsérvese que el análisis efectuado es de tipo retroactivo, al referirse a medidas de eficiencia implantadas en el año 2008 (desde el 21 de abril hasta noviembre). En este sentido, y atendiendo a las consideraciones anteriores, se fija el 6 mayo 2009 como fecha de fin del período de verificación, debido a que el cambio de modo de operación de la caldera de recuperación es una

modificación operativa significativa que no está relacionada con la implantación de las MAE.

Si se hace referencia a la fecha en la cual finalizó la implantación de las MAE, el comienzo del período de verificación debería situarse a finales de agosto 2008. No obstante, el comportamiento anómalo prolongado del medidor de vapor de BP consumido en el desgasificador obligó a la eliminación de este largo tramo objeto de error, de forma que la fecha de comienzo se fija en el 17 noviembre 2008. Se remarca la necesidad de sumo cuidado en actuaciones como estas, ya que filtrados masivos sobre tramos consistentes de horas de operación que afectan a todas las variables de la base de datos (filtrado “por filas”, atendiendo a la terminología utilizada en la [fase 5](#)) nunca son recomendables, por estar empobreciendo la muestra de datos disponible. En este caso específico se ha considerado oportuno proceder a la eliminación del período de anomalía, por el hecho de que la variable en cuestión tiene prioridad máxima, al tratarse justamente de uno de los parámetros a modelar y para los cuales se quiere generar la línea base de consumo.

5. Fase 5. Selección y tratamiento de los datos

En esta fase del estudio se genera la base de datos definitiva que contiene los valores medidos de las variables a utilizar para el modelado. El procesamiento de los datos se estructura en las siguientes etapas:

5.1 Recogida de datos

Los históricos de operación pueden obtenerse del sistema de control distribuido de la planta, previa adaptación del formato y eliminación de las discontinuidades en las horas de operación y otras anomalías. Para la planta de cogeneración se procedió a la descarga de los datos medidos almacenados en el sistema de control distribuido relativos a 89 variables monitorizadas, desde agosto 2006 hasta diciembre 2009, por un total de 30.464 horas de operación.

5.2 Eliminación de datos no representativos

Se eliminan los datos históricos correspondientes al funcionamiento fuera de diseño de la planta, cuando las situaciones transitorias a las que se refieren no son representativas del comportamiento del sistema. De lo contrario, en el caso de no poderse despreciar dichas situaciones (por ejemplo porque se dan durante períodos de operación significativos), podría ser necesaria la distinción entre diferentes escenarios y el posterior desarrollo de distintos modelos para cada uno de los escenarios definidos.

Obsérvese que el filtrado efectuado afecta a todas las variables monitorizadas (89 para la cogeneración) de forma indistinta. Dicho de otra forma, si se hace referencia a la estructura de la base de datos de registros, en la cual las variables monitorizadas están organizadas por columnas y las filas representan las horas de operación, el filtrado efectuado es del tipo “por filas”, es decir, cada vez que se filtra un registro se están eliminando 89 datos referidos a la misma hora de funcionamiento de la planta.

En la planta de cogeneración este primer filtrado coincidió con la eliminación de los datos correspondientes a la operación a carga parcial de la turbina de gas (ciclos de lavado), ya que no se vio necesaria la generación de un modelo específico para un porcentaje tan pequeño de horas de funcionamiento, debido al pequeño impacto que habría tenido sobre los resultados globales. Dicho filtrado se corresponde con la eliminación de los puntos de operación marcados en rojo en la [figura 3](#).

5.3 Eliminación de variables fuera del alcance del modelado

Se eliminan las mediciones que se refieren a salidas de equipos fuera del volumen de control, así como variables internas de equipos que no tienen influencia sobre las variables objetivo (salidas) de los modelos. Para la planta de cogeneración, dicha selección consiste en:

- Eliminación de las mediciones de potencia eléctrica activa y reactiva de la turbina de vapor. No son valores de interés, ya que la turbina de vapor está excluida del volumen de control de modelado.
- Eliminación de los registros de temperatura de los gases de escape en puntos intermedios dentro de la caldera de recuperación (temperaturas entre intercambiadores). No son de interés para el análisis debido a que no influyen sobre las salidas seleccionadas.

De esta forma el conjunto de datos se vio reducido desde 89 variables iniciales hasta 81 variables. De acuerdo a la terminología introducida anteriormente, esta operación de filtrado es del tipo “por columna”.

5.4 Selección de las variables objeto de la fase de modelado

Entre todos los registros disponibles, se seleccionan sólo aquellas variables que corresponden a las salidas del modelo (definidas en la [fase 3.2](#)) y al conjunto preliminar de entradas al modelo (selección efectuada en la [fase 3.3](#)).

Para la planta de cogeneración, esta fase de filtrado “por columnas” conllevó la reducción del número de variables desde 81 a 27. Cabe observar que, aunque un número limitado de registros proporcione mejor manejabilidad y facilidad de gestión de la base de datos, se aconseja tener mucha precaución a la hora de eliminar las variables y tener siempre en consideración cuál es la técnica empleada en la fase posterior de modelado. Por ejemplo, en el caso de utilizarse modelos termodinámicos,

las temperaturas intermedias en el interior de la caldera de recuperación no deberían eliminarse, ya que serían de utilidad para la validación del modelo desarrollado para la caldera y contrastar los resultados del mismo con los valores medidos de los perfiles de temperatura internos a la caldera.

El conjunto inicial de datos de la planta de cogeneración se redujo así desde 89 hasta 27 variables que tienen potencial influencia sobre los objetivos a modelar.

Cabe observar que, para ser rigurosos, las [fase 5.3](#) y [5.4](#) son redundantes, en el sentido de que la selección efectuada en la [fase 5.4](#) podría prescindir, en principio, de la [fase 5.3](#). Aun así, se destaca la importancia de la selección preliminar efectuada en la [fase 5.3](#) entre el conjunto de medidores disponibles. Dicha selección, que puede ser considerada una pauta “organizativa” del análisis, permite, junto con los planos de la instalación, esclarecer la cantidad y la localización de las variables monitorizadas, información que se considera de alta utilidad y soporte a la hora de efectuar la selección preliminar de las entradas al modelo ([fase 3.3](#)).

5.5 Eliminación de datos anómalos y nulos

Se localizan y se eliminan las anomalías asociadas con sensores defectuosos o errores en el sistema de adquisición de datos, así como de los registros nulos existentes en el conjunto de datos. Aunque los datos nulos no puedan definirse propiamente anomalías, se procede a su eliminación para evitar la presencia de “vacíos” en el historial de datos, factor que determinaría errores en las fases posteriores de entrenamiento de los modelos ([fase 6.3](#)).

Más en concreto, en esta fase se procede a la eliminación de tres tipos de registros:

- Registros constantes durante períodos prolongados de tiempo, que indican fallos continuados de los medidores.
- Registros nulos.
- Registros fuera de rango. Se trata de las mediciones que caen muy por encima o muy por debajo de los límites mínimos y máximos entre los cuales está comprendida la gran mayoría de datos medidos de la misma variable.

Cabe resaltar la importancia de efectuar el filtrado propuesto en esta fase, del tipo “por filas”, sólo tras haber procedido a la selección de variables de las [fases 5.3](#) y [5.4](#), y la necesidad de mantener este orden de proceder para el tratamiento de los datos. De otra forma, la inversión del orden de las operaciones de filtrado ([fase 5.5](#) efectuada anteriormente a las [fases 5.3](#) y [5.4](#)) podría suponer filtraciones excesivas de registros, ya que se podrían estar eliminando inútilmente horas de operación por haber detectado anomalías en las mediciones de algunas variables que en realidad no son de interés para el estudio.

5.6 Variables calculadas

Para algunas variables de entrada puede que no se disponga de valores medidos, por lo que se requiere su cálculo a partir de otros registros. En la planta de cogeneración se aplica la conservación de masa y energía para el cálculo de:

- Caudal másico de condensados a la entrada del intercambiador HX2.
- Temperatura de los condensados a la entrada del intercambiador HX1.

Cabe señalar que los cálculos efectuados fueron de utilidad para el aislamiento y la eliminación de algunos registros erróneos, correspondientes a una operación física incoherente de los intercambiadores de calor. Tras esta fase, el conjunto de datos de la planta de cogeneración se amplió desde 27 hasta 29 variables.

5.7 Variables contenidas implícitamente en datos medidos

Las mediciones a menudo reflejan tendencias de difícil detección por parte de los modelos generados, a menos que el conocimiento físico del sistema permita la adaptación y el ajuste de dichos modelos para reproducirlas correctamente.

Para la planta de cogeneración se procedió a introducir una variable contador de tiempo, que representa las horas de funcionamiento de la planta y que se reinicia en cero cada vez que se realiza una limpieza off-line de la turbina de gas. Esta simple forma de proceder permite que los modelos sean capaces de captar y reproducir fenómenos complejos como la degradación de la turbina de gas (y por tanto la disminución gradual de la producción de electricidad entre ciclos de limpieza off-line) y el aumento gradual de la caída de presión en los filtros de aire de entrada a la turbina. Obsérvese que no sería correcto utilizar la pérdida de carga del aire a la entrada de la turbina de gas como entrada a los modelos, debido a que esta variable se vio afectada por las MAE, lo cual llevaría a una cuantificación errónea de los ahorros.

Tras esta fase, el conjunto de datos de la planta de cogeneración se amplió desde 29 hasta 30 variables.

5.8 Resultados

A continuación se resumen los resultados de la aplicación de las operaciones de selección de variables y filtrado de registros en la planta de cogeneración.

5.8.1 Selección de variables

La [tabla 4](#) resume las acciones de selección de las variables monitorizadas (filtrados “por columnas” efectuados en las [fases 5.3](#) y [5.4](#)) y de generación de nuevas variables ([fases 5.6](#) y [5.7](#)) para la planta de cogeneración.

Equipo/ Zona	Categoría	Variable	Id. medidor	Nº	Eliminación medidores repetidos	Iª selección (fase 4.3)	IIª selección (fase 4.4)	Variables calculadas + tiempo (fases 4.6 & 4.7)	Posible candidato para el modelado de:
						81 variables seleccionadas	27 variables seleccionadas	30 variables seleccionadas	
Turbina de gas	Combustible (gas natural)	Caudal volumétrico	3PHD-COFY_121.PV- VALOR (Nm3/h)	1	X	X	X	X	Pel TG/Pcons TG/Ppbihy vap TG
		Poder calorífico inferior (PCI)	3PHD-UGG02.281- VALOR (kcal/Nm3)	2	X	X	X	X	Pel TG/Pcons TG/Ppbihy vap TG
		Poder calorífico inferior (PCI)	3PHD-CGGNC.PV- VALOR	3	Repetido				
		Temperatura	3PHD-COT1_015.PV- VALOR (°C)	4	X	X	X	X	Pel TG/Pcons TG/Ppbihy vap TG
		Temperatura	3PHD-COT1_017.PV- VALOR (°C)	5	Repetido				
		Presión de alimentación	3PHD-CGPI_067.PV- VALOR (bar)	6	X	X	X	X	Pel TG/Pcons TG/Ppbihy vap TG
		Presión de entrada a mecheros	3PHD-CGPI_004.PV- VALOR (kg/cm2g)	7	X	X	X	X	Pel TG/Pcons TG/Ppbihy vap TG
		Pérdida de carga en mecheros	3PHD-CGOL_005.PV- VALOR (kg/cm2g)	8	X	X			
		Índice de Wobbe	3PHD-CGAL_013.PV- VALOR (kJ/Nm3)	9	X	X			
		Densidad	3PHD-UGG02.R01- VALOR (kg/nm3)	10	X	X	X	X	Pel TG/Pcons TG/Ppbihy vap TG
Turbina de gas	Generación Eléctrica	Potencia activa en bornes	3PHD-CEI1_064.PV- VALOR (MW)	11	X	X	X	X	Pel TG
		Potencia reactiva en bornes	3PHD-CGJI_510.PV- VALOR (MW)	12	X	X			
		Presión	3PHD-CGPI_120.PV- VALOR (kg/cm2g)	13	X	X	X	X	Pel TG/Pcons TG
		Temperatura	3PHD-CGT1_068.PV- VALOR (°C)	14	X	X			
		Caudal mássico	3PHD-CGFI_083.PV- VALOR (t/h)	15	X	X	X	X	Pel TG/Pcons TG
		Pérdida de carga en filtros	3PHD-CGPI_070.PV- VALOR (mm H2O g)	16	X	X	X	X	Pel TG/Pcons TG
		Pérdida de carga en enfriador	3PHD-CGPI_070.PV- VALOR (mmH2O g)- 3PHD-CGPI_071.PV- VALOR (mmH2O g)	17	X	X			
		Ángulo ISV	3PHD-CGXI_070.PV- VALOR (%)	18	X	X			Descartado por modelar sólo carga total TG
		Ángulo ISV	3PHD-CGXI_069.PV- VALOR	19	Repetido				
		Presión descarga compresor	3PHD-CGPI_066.PV- VALOR (kg/cm2g)	20	X	X			
Turbina de gas	Propiedades aire de admisión	Velocidad de giro	3PHD-CGSI_062.PV- VALOR (r.p.m.)	21	X	X			
		Temperatura ambiente	3PHD-CGT1_071.PV- VALOR (°C)	22	X	X	X	X	Pel TG/Pcons TG /hy vap TG/ConstvapDesg
		Humedad relativa	3PHD-CGAI_001.PV- VALOR	23	X	X	X	X	Pel TG/Pcons TG /hy vap TG
		Presión atmosférica	3PHD-CGPI_002.PV- VALOR (mbar)	24	X	X	X	X	Pel TG/Pcons TG /hy vap TG
		Temperatura tás filtros	3PHD-CGT1_070.PV- VALOR (°C)	25	X	X			
		Presión entrada enfriador	3PHD-CGPI_070.PV- VALOR (mm H2O g)	26	X	X			
		Presión salida enfriador	3PHD-CGPI_071.PV- VALOR (mm H2O g)	27	X	X			
		Temperatura brida entrada compresor	3PHD-CGT1_021.PV- VALOR (°C)	28	X	X			
		Temperatura brida salida compresor	3PHD-CGT1_031.PV- VALOR (°C)	29	X	X			
		Temperatura brida salida compresor	3PHD-CGT1_032.PV- VALOR (°C)	30	Repetido				
Turbina de gas	Gases de escape	Temperatura	3PHD-CGT1_019.PV- VALOR (°C)	31	X	X			
		Presión	3PHD-CUPI_048.PV- VALOR (mm H2O g)	32	X	X			

(continúa en la página siguiente)

(sigue de la página anterior)										
Equipo/ Zona	Categoría	Variable	Id. medidor	Nº	Eliminación medidores repetidos	Iª selección (fase 4.3)	IIª selección (fase 4.4)	Variables calculadas + tiempo (fases 4.6 & 4.7)	Posible candidato para el modelado de:	
Caldera de recuperación	Agua	Caudal másico	3PHD.CUFC_006.PV- VALOR (t/h)	33	X	X				
		Conductiv dad	3PHD.CUAL_020.PV- VALOR (µS/cm)	34	X	X				
		Temperatura de entrada	3PHD.CUTI_019.PV- VALOR (°C)	35	X	X				
		Presión de entrada	3PHD.CUPI_058.PV- VALOR (kg/cm2g)	36	X	X				
	Gases	Temperatura de salida	3PHD.CUTI_056.PV- VALOR (°C)	37	X	X				
		Presión de salida	3PHD.CUPI_094.PV- VALOR (mm H2O g)	38	X	X				
		Caudal volumétrico	3PHD.COB1.CAU- VALOR (Nm3/h)	39	X	X				
		Contenido de oxígeno	3PHD.CUAL_086.PV- VALOR (%V/V)	40	X	X				
		Contenido de SO ₂	3PHD.CUAY_102.PV- VALOR (mg/Nm3)	41	X	X				
		Contenido de partículas	3PHD.CUAY_103.PV- VALOR (mg/Nm3)	42	X	X				
Condiciones operativas	Contenido de NO _x	3PHD.CUAY_101.PV- VALOR (mg/Nm3)	43	X	X	X	X	X	Pal TGFIcons TGI/hy vap TG	
	Presión	3PHD.CUPI_003.PV- VALOR (bar)	44	X	X	X	X	X	Ppob	
	Temperatura	3PHD.CUTI_352.PV- VALOR (°C)	45	X	X	X	X	X	Ppob	
	Temperatura	3PHD.CUTI_353.PV- VALOR (°C)	46	Repetido						
	Temperatura	3PHD.CUTI_354.PV- VALOR (°C)	47	Repetido						
	Temperatura	3PHD.CUTI_355.PV- VALOR (°C)	48	Repetido						
Gases	Temperatura	3PHD.CUTI_088.PV- VALOR (°C)	49	X	X					
	Presión	3PHD.CUPI_057.PV- VALOR (mm H2O g)	50	X	X					
Gases	Temperatura de entrada	3PHD.CUTI_084.PV- VALOR (°C)	51	X	X					
	Temperatura de entrada	3PHD.CUTI_085.PV- VALOR (°C)	52	Repetido						
	Temperatura de entrada	3PHD.CUTI_086.PV- VALOR (°C)	53	Repetido						
	Temperatura de entrada	3PHD.CUTI_087.PV- VALOR (°C)	54	Repetido						
Vapor	Temperatura de entrada	3PHD.CUTI_088.PV- VALOR (°C)	55	Repetido						
	Temperatura de entrada	3PHD.CUTI_004.PV- VALOR (°C)	56	X	X	X				
	Temperatura de salida	3PHD.CUTC_003.PV- VALOR (°C)	57	X	X	X				
	Caudal másico	3PHD.CUFI_015.PV- VALOR (t/h)	58	X	X	X				
ATEMPERADOR	Agua de alimentación	Presión	3PHD.COPC_076.PV- VALOR (bar)	59	X	X				
		(continúa en la página siguiente)								

(sigue de la página anterior)											
Equipo/ Zona	Categoría	Variable	Id. medidor	Nº	Eliminación mediciones repetidos	Iª selección (fase 4.3)	IIª selección (fase 4.4)	Variables calculadas + tiempo (fases 4.6 & 4.7)	Posible candidato para el modelado de:		
Caldera de recuperación	SORECALENTADOR SC2	Vapor	3PHD.CUTC_003.PV- VALOR (°C)	60	X	X					
		Gases	3PHD.CUTL_078.PV- VALOR (°C)	61	X	X					
		Temperatura de entrada	3PHD.CUTL_079.PV- VALOR (°C)	62	Repetido						
		Temperatura de entrada	3PHD.CUTL_080.PV- VALOR (°C)	63	Repetido						
		Temperatura de entrada	3PHD.CUTL_081.PV- VALOR (°C)	64	Repetido						
		Temperatura de entrada	3PHD.CUTL_082.PV- VALOR (°C)	65	Repetido						
	SORECALENTADOR FINAL (SC3)	Temperatura de entrada	3PHD.CUTL_083.PV- VALOR (°C)	66	Repetido						
		Vapor	Caudal mástico	3PHD.CUF.X048.PV- VALOR (ft³)	67	X	X	X	X	Pcbtr Cons/VapDesg	
			Temperatura de salida	3PHD.CUTL_001.PV- VALOR (°C)	68	X	X	X	X	Pcbtr Cons/VapDesg	
			Presión de salida	3PHD.CUPC_001.PV- VALOR (bar)	69	X	X	X	X	Pcbtr Cons/VapDesg	
	SORECALENTADOR RECIENTE DE PURGAS	Gases	Temperatura de entrada	3PHD.CUTL_053.PV- VALOR (°C)	70	X					
			Presión de entrada	3PHD.CUPL_046.PV- VALOR (mm H2O g)	71	X					
			Presión de entrada	3PHD.CUPL_054.PV- VALOR (mm H2O g)	72	Repetido					
		Agua (purga)	Caudal mástico	3PHD.CUFI_014.PV- VALOR (ft³)	73	X	X	X	X	X	Pcbtr
			Caudal volumétrico	3PHD.CUFI_001.PV- VALOR (Nm3/h)	74	X	X				Descartado porque no se quema FG
			Temperatura	3PHD.COTL_016.PV- VALOR (°C)	75	X	X				
POST-COMBUSTIÓN	Gas natural	Caudal volumétrico	3PHD.COFY_283.PV- VALOR (Nm3/h)	76	X	X					
		Poder calorífico inferior (PCI)	3PHD.CUG02.281- VALOR (kcal/Nm3)	77	Repetido						
	Condiciones operativas	Presión	3PHD.COPC_040.PV- VALOR (kg/cm2g)	78	X	X	X	X	X	Cons/VapDesg	
		Temperatura	3PHD.CUTC_210.PV- VALOR (°C)	79	X	X	X	X	X	Cons/VapDesg	
Desgasificador	Vapor de alimentación	Caudal mástico	3PHD.COFU_080.PV- VALOR (ft³)	80	X	X	X	X	Cons/VapDesg		
		Temperatura	3PHD.CUTL_018.PV- VALOR (°C)	81	X	X	X				
	Agua desgasificada	Caudal mástico	3PHD.COFU_091.PV- VALOR (ft³)	82	X	X	X				
(continúa en la página siguiente)											

(sigue de la página anterior)

Equipo/ Zona	Categoría	Variable	Id. medidor	Nº	Eliminación medidores repetidos	Iª selección (fase 4.3)	IIª selección (fase 4.4)	Variables calculadas + tiempo (fases 4.6 & 4.7)	Posible candidato para el modelado de:
Tren de precalentamiento agua	HX1	Agua tratada	3PHDCGTL071.PV- VALOR (°C)	83	X	X			
			3PHDCOFI089.PV- VALOR (°h)	84	X	X			
		Condensados	3PHDCOPC085.PV- VALOR (kg/cm2g)	85	X	X			
			3PHDCUFI307.PV- VALOR (m3/h)	86	X	X	X	X	Cons/Vap/Desg
		Temperatura de entrada	Cálculo (1)	87				X	Cons/Vap/Desg
		Temperatura de salida	3PHDCOTC084.PV- VALOR (°C)	88	No disponible				No monitorizado en el periodo de análisis
		Temperatura de entrada	3PHDCDTL520.PV- VALOR (°C)	89	X	X			
		Temperatura de salida	3PHDCDTL521.PV- VALOR (°C)	90	X	X			
	HX2	Temperatura de entrada	3PHDCUTL522.PV- VALOR (°C)	91	X	X	X	X	Cons/Vap/Desg
		Temperatura de salida	3PHDCUTL523.PV- VALOR (°C)	92	X	X			
		Caudal másico	Cálculo (2)	93				X	Cons/Vap/Desg
	Turbina de vapor	Caudal másico	3PHDCUF004B.PV- VALOR (°h)	94	Repetido				
		Temperatura	3PHDCUTI001.PV- VALOR (°C)	95	Repetido				
		Presión	3PHDCVPL001.PV- VALOR (kg/cm2g)	96	Repetido				
		Temperatura	3PHDCVTI006.PV- VALOR (°C)	97	X	X			
		Presión	3PHDCVPL007.PV- VALOR (kg/cm2g)	98	X	X			
		Caudal másico	3PHDCVFI211.PV- VALOR (°h)	99	X	X			
		Temperatura	3PHDCVTI011.PV- VALOR (°C)	100	X	X			
		Presión	3PHDCVPL012.PV- VALOR (kg/cm2g)	101	X	X			
Atemperadores	Regulación	Caudal másico	3PHDCVFI212.PV- VALOR (°h)	102	X	X			
		Potencia activa en bornes	3PHDCVLI124.PV- VALOR (MW)	103	X				
		Potencia reactiva en bornes	3PHDCVLI125.PV- VALOR (MV)	104	X				
		Velocidad de giro	3PHDCVSU135.PV- VALOR (r.p.m.)	106	X				
		Caudal másico	3PHDCVFI220.PV- VALOR (°h)	107	X	X			
		Temperatura	3PHDCVTC021.PV- VALOR (°C)	108	X	X			
		Temperatura	3PHDCVTI204.PV- VALOR (°C)	109	X	X			
		Presión	3PHDCVPC206.PV- VALOR (kg/cm2g)	110	X	X			
	Vapor BP exportado - salida atemp.	Caudal másico	3PHDCVFI213.PV- VALOR (°h)	111	X	X			
		Temperatura	3PHDCVTC210.PV- VALOR (°C)	112	X	X			
		Presión	3PHDCVPC209.PV- VALOR (kg/cm2g)	113	X	X			
		Caudal másico	3PHDCVFI214.PV- VALOR (°h)	114	X	X			
		Contador de horas de operación						X	Variable extra introducida para el modelado

Tabla 4. Selección de variables monitorizadas y cálculo de nuevas variables.

5.8.2 Filtrado de registros

El período de modelado ha sido definido en la [fase 4](#) y se constituye de las horas de operación comprendidas entre el 16 febrero 2007 (18.00^h) y el 21 abril 2008 (17.00^h), que corresponde a 10.320 registros. No obstante, un fallo prolongado en el medidor de emisiones de NO_x obligó a la eliminación de los registros durante los primeros meses de operación, de forma que el conjunto final de datos se corresponde con el período entre el 12 de junio 2007 (07.00^h) y el 21 abril 2008 (17.00^h), que incluye un total de 7.547 horas de operación.

Las operaciones de filtrado previas al entrenamiento de los modelos relativos a la turbina de gas dieron los siguientes resultados:

1. Potencia eléctrica generada en la turbina de gas:

- ✓ Se eliminan los datos correspondientes al funcionamiento a carga parcial de la turbina (ángulo IGV inferior a 86°).
- ✓ Sobre la base de datos obtenida del filtrado, se procede a la eliminación de los registros correspondientes a transitorios y paradas, operación a baja carga por rentabilidad de la operación y bajadas de carga por limpieza “carbo-blasting”.

El número de registros disponibles se reduce desde 7.547 hasta 6.713 (834 registros eliminados, el 11,1% del conjunto inicial).

2. Consumo de combustible en la turbina de gas:

Se filtran los valores fuera de rango (“outliers”) del consumo de la turbina, con el objetivo de que los valores a utilizar para el modelado estén comprendidos entre valores razonables, tanto para el caudalímetro de gas natural alimentado a la turbina (valores entre 10.500 y 12.500 Nm³/h) como para la potencia térmica consumida calculada (112 MW_{PCI} es el valor límite inferior empleado para el filtrado).

El filtrado corresponde a la eliminación de 308 registros (4,1% de la base de datos de partida), siendo la base de datos final constituida por 6.405 registros, que corresponde al 84,9% del conjunto de registros inicial.

La eliminación de los datos fuera de rango ha sido estandarizada utilizando una técnica mixta que incluye el cálculo de la media móvil y el sucesivo filtrado “por bandas” alrededor de dicha media. En la [figura 10](#), en la cual se muestran los resultados de los filtrados efectuados, se pueden apreciar los beneficios asociados al uso de la media móvil, representados por sus propiedades de suavización de las fluctuaciones en el corto plazo y exaltación de las tendencias en el medio plazo. Adicionalmente al filtrado por bandas alrededor de media móvil, se han aplicado los cortes por banda (valor límite inferior y superior) de potencia consumida en la turbina de gas comentados anteriormente. Por último, en las zonas en las cuales la utilidad de la media móvil se ve perjudicada por las altas concentraciones de valores fuera de rango, se ha procedido a la selección directa de las áreas de datos a filtrar, tal y como se puede apreciar en el caso de la potencia consumida en la turbina.

De los diagramas mostrados se pueden observar los principales efectos de los filtrados efectuados (zonas remarcadas en las series de datos filtrados en la [figura 10](#)), a saber:

- El filtrado efectuado sobre la potencia eléctrica de la turbina repercute principalmente sobre las zonas de máxima potencia de la turbina, lo cual indica una presencia consistente de datos correspondientes a bajada de carga impuesta por la rentabilidad de la unidad. Por esta razón los tramos de operación a alta potencia se caracterizan por una mayor dispersión de los registros (aunque no tan fácilmente detectable desde los diagramas) tras la realización del filtrado.
- El segundo de los filtrados efectuados (potencia consumida en la turbina) determina una eliminación de registros concentrada y por ello un empobrecimiento de la muestra en el tramo final de la base de datos, más en concreto en la segunda semana del mes de abril 2008.

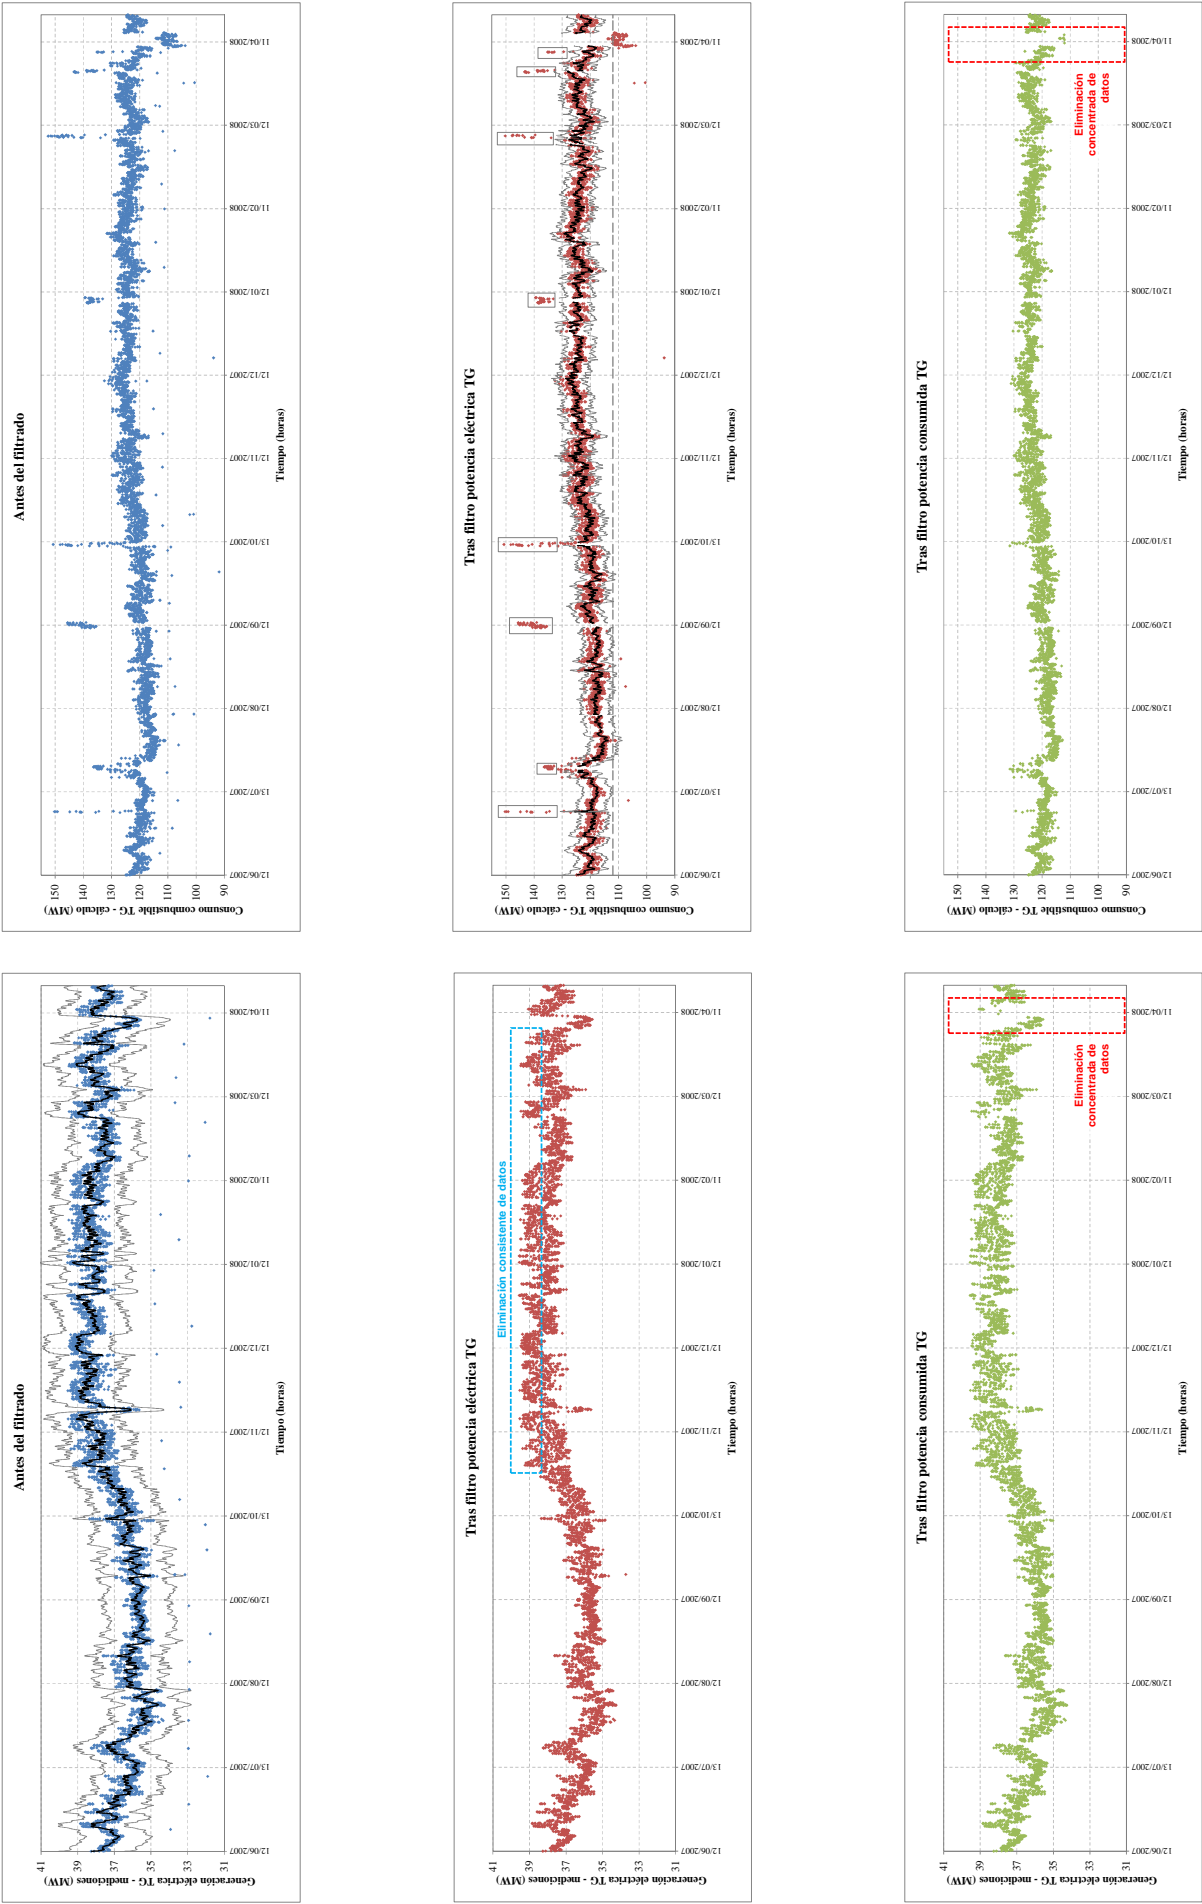


Figura 10. Filtrado de la base de datos previo al entrenamiento de los modelos de la turbina de gas.

6. Fase 6. Modelado

La técnica de modelado propuesta para el desarrollo de esta fase son las redes neuronales artificiales (RNA). Como se ha comentado en la sección introductoria de este informe, este tipo de técnica se caracteriza por en alto potencial de detección de los patrones de comportamiento no lineal que gobiernan la operación de los sistemas energéticos y la elevada capacidad para reproducir su comportamiento con niveles satisfactorios de precisión.

6.1 Modelado con redes neuronales artificiales. Introducción

Una red neuronal artificial (RNA) es una técnica estadística de modelado adaptativa no lineal que utiliza datos externos para establecer su estructura y "aprender" a reproducir el comportamiento implícitamente contenido en esos datos. Una RNA consta de un conjunto de neuronas artificiales interconectadas y estructuradas en capas, que transmiten la información (datos de entrada) a través de la red y la procesan operando en paralelo.

Los parámetros característicos de la red se ajustan a través de procedimientos sistemáticos llamados de "aprendizaje" o "entrenamiento", dirigidos a aumentar la cercanía entre la salida de la RNA y los datos medidos objetivo del modelado. El tipo de redes empleado en este estudio es el perceptrón multicapa (PMC), que se compone de una capa de entrada, una o más capas ocultas y una capa de salida. El PMC es una red multicapa de propagación hacia delante en la cual cada capa está totalmente conectada a la siguiente, y todas las conexiones llevan asociados pesos multiplicativos ("pesos sinápticos"). Está demostrado que una sola capa oculta es suficiente para aproximar cualquier función continua hasta cualquier nivel de exactitud (teorema de la "aproximación universal" [115]). No obstante, la complejidad de la función que representa el modelo y el nivel de precisión de aproximación requerido son factores que contribuyen a aumentar el número de neuronas necesarias para la consecución del objetivo. En este sentido, está también comprobado que los modelos pueden mejorarse introduciendo una segunda capa oculta, pudiéndose de esta forma obtener mayores niveles de precisión reduciendo el número total de neuronas de la red. En línea general, la utilización de la segunda capa oculta de neuronas es especialmente beneficiosa cuando aumenta el número de entradas y/o salidas del modelo y cuando las funciones a modelar presentan perfiles muy variables con muchas lomas y valles [52].

El entrenamiento de la RNA se define como el proceso que permite determinar los pesos sinápticos adecuados para todas las conexiones de la red, de manera que sea minimizada la cercanía entre las salidas del modelo y los datos medidos de entrada objetivo del modelado. Dependiendo de la serie de datos a modelar, el objetivo es establecer la mejor estructura de la RNA, es decir, el número de capas y de las

neuronas en cada capa, la función de transferencia asociada a cada capa y el algoritmo de entrenamiento. La [figura 11](#) muestra la estructura general de una red neuronal con dos capas ocultas de neuronas totalmente interconectadas, así como la acción de transformación (función suma y función de activación) ejercida por cada una de las neuronas de la red.

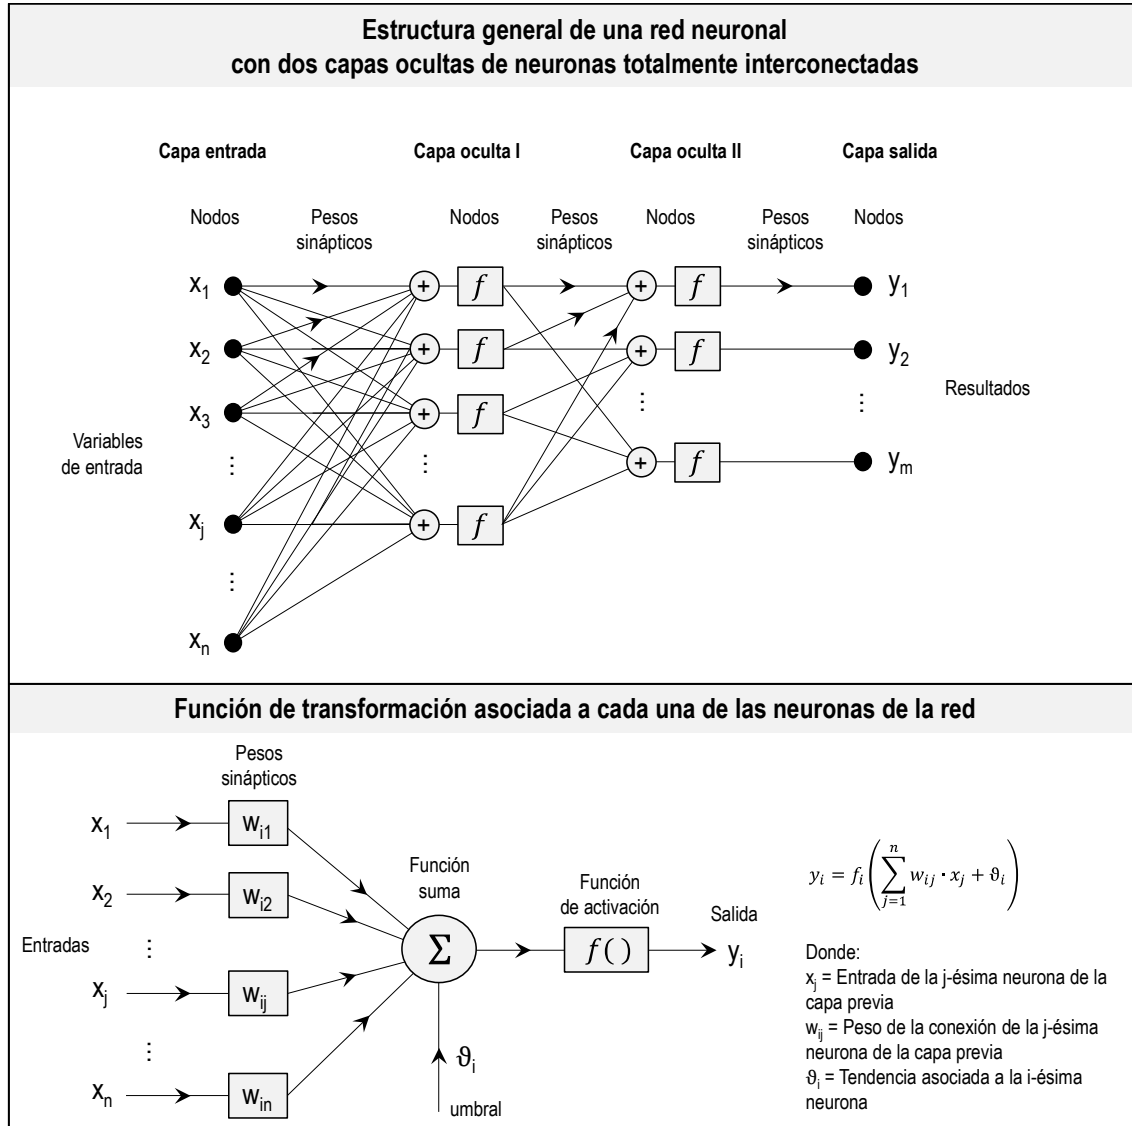


Figura 11. Estructura general de una RNA y función de transformación asociada a las neuronas.

En cada elemento de procesamiento de la red (neurona), los valores de entrada son multiplicados por unos pesos sinápticos ajustables y sucesivamente sumados y procesados por una función de transferencia que genera la salida de la neurona. De esta forma, los valores de las variables de entrada se transmiten a través de la red, capa por capa, hasta obtener un conjunto de datos de salida. La red aprende mediante el examen de los registros individuales, generando una predicción para cada registro, y realizando los ajustes a los pesos cada vez que se produce una predicción incorrecta (los errores se generan mediante la comparación las salidas de la red con los valores deseados). Esta operación se repite cíclicamente de forma que, en cada ciclo de entrenamiento (también llamado “época” de entrenamiento), la red continúa

mejorando la precisión de sus predicciones. A este proceso se le denomina proceso de aprendizaje supervisado. Existen distintos criterios para determinar la parada del entrenamiento y normalmente el proceso se detiene cuando se cumple una de las siguientes condiciones:

- Se alcanza el nivel mínimo de precisión establecido.
- El número de iteraciones efectuadas iguala el número máximo de épocas del algoritmo.
- Aparición del fenómeno de “sobre-ajuste” (comentado más adelante).

Antes del comienzo del proceso de entrenamiento, es necesario aleatorizar el conjunto de datos y dividirlo en tres subconjuntos: entrenamiento, validación cruzada y test.

El conjunto de entrenamiento se utiliza para llevar acabo el ajuste de los pesos sinápticos (proceso de aprendizaje de la red), mientras que el conjunto de validación cruzada se usa para evitar el sobre-entrenamiento de la red. Con esta designación se indica el fenómeno según el cual a partir de un cierto número de iteraciones la red se vuelve excesivamente “especializada” en reproducir los patrones con los que fue entrenada, perdiéndose así su capacidad de generalización y viéndose perjudicado su potencial para reconocer patrones nuevos no utilizados durante el entrenamiento. Para solucionar este problema se implementa en el algoritmo de entrenamiento una técnica denominada “parada temprana” [74]: si bien el conjunto de entrenamiento se sigue utilizando de la forma habitual, el algoritmo utiliza el conjunto de validación cruzada como una serie de datos independiente y nueva para la red, y comprueba ambos errores obtenidos, tanto con el conjunto de entrenamiento como con el de validación. Siempre y cuando no se haya cumplido el número máximo de iteraciones o el nivel mínimo de precisión, el entrenamiento se detiene cuando la diferencia en el error entre los dos conjuntos alcanza un valor dado, es decir, antes de la aparición del fenómeno del sobre-ajuste de la RNA.

Por último, finalizado el entrenamiento, se utiliza el subconjunto de datos de test para evaluar la capacidad de predicción de la RNA, comparando las salidas generadas por la red con los valores deseados para un conjunto de datos no utilizados en el entrenamiento. Cabe observar que una red adecuadamente entrenada debería presentar errores de predicción similares en los tres subconjuntos de datos.

Como se ha comentado anteriormente, el tipo de redes neuronales propuesto en este análisis es el PMC y para el ajuste de los parámetros de la red se ha utilizado el proceso de aprendizaje supervisado. Más adelante se describen las etapas que componen la fase de modelado, y se aplican al caso concreto de la unidad de cogeneración.

6.2 Selección de las variables de influencia

En la [fase 3.3](#) se ha procedido a la selección de un conjunto preliminar de variables, que potencialmente podrían utilizarse como entradas para los modelos. Para determinar la importancia relativa de las variables seleccionadas (predictores) sobre el objetivo final (registros) debe realizarse un análisis de sensibilidad que permita observar

la entidad de los cambios inducidos en el modelo atribuibles a cada uno de los predictores. Dicho análisis de sensibilidad se lleva a cabo con el método propuesto por Saltelli [116], que es el mismo utilizado en el algoritmo de predicción de importancia implementado en el software estadístico utilizado para el estudio: IBM SPSS Modeler 14.1.0. Este método se basa en el cálculo de la reducción de la varianza en el modelo atribuible a cada variable de entrada. En concreto, se calcula un índice de sensibilidad para cada uno de los predictores:

$$S_j = \frac{V(y) - E(V(y|x_j))}{V(y)} \quad (1)$$

donde:

- $V(y)$ es la varianza de la salida del modelo asociada a todos los predictores x_i , calculada como

$$V(y) = \frac{1}{N-1} \sum_{r=1}^N f^2(x_1^{(r)}, x_2^{(r)}, \dots, x_k^{(r)}) - E^2(y) \quad (2)$$

siendo

- ✓ r el número de registros
- ✓ $f(x)$ la función modelada de los predictores x_i
- ✓ $E(y)$ el valor promedio de y : $E(y) = \frac{1}{N} \sum_{r=1}^N f(x_1^{(r)}, x_2^{(r)}, \dots, x_k^{(r)})$ (3)
- $E(V(y|x_j))$ es el valor promedio de la varianza de la salida asociada al único predictor x_j . Desde el punto de vista numérico computacional, el numerador de la ecuación (1) puede calcularse dividiendo la muestra de datos de entrada en dos matrices distintas y aplicando la fórmula

$$V(y) - E(V(y|x_j)) = \frac{1}{N-1} \sum_{r=1}^N f(x_1^{(r)}, x_2^{(r)}, \dots, x_k^{(r)}) f(x_1^{(r')}, x_2^{(r')}, \dots, x_j^{(r')}, \dots, x_k^{(r')}) - E'^2(y) \quad (4)$$

donde el primer término del lado derecho de la ecuación (4) es conceptualmente análogo al término correspondiente de la ecuación (2) y se obtiene del "remuestreo" de todas las entradas menos x_j , mientras que el término $E'^2(y)$ puede calcularse como

$$E'^2(y) = \frac{1}{N} \sum_{r=1}^N f(x_1^{(r)}, x_2^{(r)}, \dots, x_k^{(r)}) f(x_1^{(r')}, x_2^{(r')}, \dots, x_k^{(r')}) \quad (5)$$

Finalmente se puede determinar la importancia del predictor:

$$PI_j = \frac{S_j}{\sum_{i=1}^k S_i} \quad (6)$$

Como es fácil de entender, se trata de un proceso iterativo que implica la repetición de la fase de entrenamiento del modelo (fase 6.3 comentada posteriormente) y la observación de los cambios producidos en las prestaciones del modelo (fase 6.5).

Una vez que ha sido determinada la importancia de los predictores, es recomendable proceder a realizar unos entrenamientos ulteriores del modelo, eliminando los predictores de entrada menos relevantes y observando la entidad de los cambios producidos en la capacidad de predicción del modelo. Esta forma de proceder, sugerida también por Castellano et al. [117], responde al criterio del compromiso entre

precisión requerida y practicidad de los modelos generados, ya que a menudo la exclusión de algunas variables de bajo nivel de influencia no afecta significativamente a la capacidad de predicción con la ventaja de aumentar la manejabilidad del modelo.

Para la planta de cogeneración objeto de estudio, la selección del conjunto definitivo de variables de entrada a los modelos ha sido efectuada empleando esta técnica de eliminación de variables en combinación con el algoritmo de predicción de importancia comentado anteriormente. Los resultados de este proceso de selección se muestran en la [tabla 5](#), en la cual se resumen también los valores de importancia calculados.

Entre las variables seleccionadas, merece la pena observar la influencia de las propiedades del combustible (y en particular de su poder calorífico) sobre la potencia generada y quemada en la turbina de gas, así como sobre la potencia térmica quemada en la post-combustión. Aunque sea nota la existencia de dependencias entre las prestaciones de las turbinas de gas y las propiedades del combustible alimentado, dichas dependencias no son de fácil determinación, ya que no existe una relación definida entre el poder calorífico del combustible y la potencia generada por la turbina. No obstante, en línea general, pueden asumirse las siguientes consideraciones generales:

- Si el combustible está constituido únicamente por hidrocarburos y no contiene gases inertes ni átomos de oxígeno, la potencia eléctrica generada aumenta al aumentar el poder calorífico. Esto se debe principalmente a que el efecto del aumento del calor específico de los gases que expanden en turbina (aumento asociado al mayor contenido en vapor de agua en los gases, a su vez debido al ratio H_2/C más elevado en el combustible) prevalece sobre el efecto contrario de reducción del caudal de combustible necesario.
- Si aumenta el contenido en inertes en el combustible (es un caso frecuentes en las planta integradas de gasificación y ciclo combinado), una disminución del poder calorífico determina un aumento de la potencia generada en turbina, siendo el aumento de caudal de combustible (y con ello de los gases expandidos en turbina) el efecto determinante.

El consumo de combustible en el post-quemador de la caldera de recuperación se ve también influenciado por las características del combustible, ya que dichas características afectan no sólo a la generación eléctrica de la turbina de gas, sino también al caudal y temperatura de sus gases de escape, y por ello a la potencia térmica entrante en la caldera.

A la luz de estas observaciones, se resalta la gran utilidad de la técnica de modelado propuesta, basada en datos históricos del sistema. Esta forma de proceder permite la captación, entre otras, de las complejas relaciones antes comentadas a partir de los registros de operación de la turbina y de la caldera de recuperación, obviando la necesidad de determinar dichas dependencias “a priori” para su posterior implementación en un simulador termodinámico.

Predictores											
Categoría	Condiciones aire de admisión TG			Propiedades combustible		Tiempo	Emisiones al atmósfera	Propiedades vapor vivo		Condiciones operativas desgasificador	
Variables de entrada al modelo	Temperatura ambiente	Humedad ambiente	Presión atmosférica	Poder calorífico inferior (PCI)	Densidad	Horas de operación	Emisiones de NO _x	Caudal másico	Presión	Presión desgasificador	Caudal másico condensados*
Generación eléctrica TG	39,6%	17,8%	6,9%	13,9%	5,9%	7,9%	8,0%	-	-	-	-
Consumo de combustible TG	27,1%	12,9%	6,7%	20,0%	14,2%	6,3%	12,8%	-	-	-	-
Consumo de combustible post-combustión	1,9%	3,1%	-	25,2%	21,0%	8,9%	-	33,1%	6,8%	-	-
Inyección de vapor MP en la TG	24,1%	10,7%	4,9%	6,7%	-	5,6%	48,0%	-	-	-	-
Consumo vapor BP en desgasificador	12,3%	-	-	-	-	-	-	8,2%	-	42,4%	37,1%
* Condensados retornados del proceso, utilizados para el precalentamiento del agua de reposición en el desgasificador											

Tabla 5. Conjunto final de variables de entrada a los modelos (predictores) y coeficientes de importancia relativos.

6.3 Entrenamiento del modelo

El objetivo de la fase de entrenamiento es conseguir el mejor ajuste entre las predicciones de los modelos y los datos medidos.

6.3.1 Arquitectura general de las redes neuronales

La estructura de la RNA elegida para el entrenamiento es del tipo PMC: red multicapa de propagación hacia delante en la cual cada capa está totalmente conectada a la siguiente. Para cada una de las salidas previamente definidas (fase 3.2) se inicializa una RNA específica y se utiliza el software IBM SPSS Modeler 14.1.0 para su configuración y entrenamiento. Las capas de salida están constituidas por una única neurona en todos los modelos entrenados, representada por cada una de las salidas seleccionadas, mientras que el número de neuronas y capas ocultas no está fijado en principio, siendo dos el número máximo de capas ocultas que ha sido contemplado. La arquitectura final de las RNA se determina mediante un proceso de prueba y error en el cual se llevan a cabo varios entrenamientos con diferentes números de capas ocultas y neuronas, con el objetivo de seleccionar unas RNA que devuelvan niveles satisfactorios de precisión de predicción, compatiblemente con el grado de complejidad de la estructura final elegida y con ello de manejabilidad de los modelos generados.

6.3.2 Funciones del algoritmo de entrenamiento

El algoritmo de entrenamiento más utilizado es el algoritmo de aprendizaje de retropropagación propuesto por Rumelhart et al. [118], que permite minimizar el error entre la salida del modelo y el conjunto de datos objetivo mediante el ajuste de los pesos asociados a las conexiones de red. Las principales funciones realizadas por el algoritmo son las que se detallan a continuación:

A Normalización de los datos de entrada

Previamente a la alimentación de la primera capa oculta de neuronas, se procede a la normalización de todos los datos de entrada a la red. Esta operación es necesaria antes de que los datos sean procesados por las neuronas a través de la función de activación, para nivelar la importancia relativa de las variables de influencia y evitar que variables caracterizadas por valores absolutos elevados eclipsen el impacto de otros registros con rangos de variabilidad inferior. De acuerdo a la necesidad de compensar este efecto de escala, en la fase de normalización se escalan todos los valores de las variables de entrada hasta que el rango de variación de cada una de ella quede comprendido entre 0 y 1. La función de transformación utilizada es

$$x'_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (7)$$

siendo

x_i' el valor escalado de la variable de entrada x para el registro i ;

x_i el valor original de x para el registro i ;

x_{min} el valor mínimo de x entre todos los registros;

x_{max} el valor máximo de x entre todos los registros.

B Inicialización de los pesos sinápticos

Al comienzo del entrenamiento, se inicializan los valores de los pesos sinápticos asociados a cada una de las neuronas de la red. Todos los pesos de la red se fijan en valores aleatorios comprendidos en el intervalo $-0,5 \leq w_{ij} \leq 0,5$.

C Presentación de los datos a la red

Se procede a alimentar la red neuronal con los valores de las variables de entrada. Como se ha comentado anteriormente, los registros se presentan por ciclos y cada ciclo (época de entrenamiento) supone la presentación a la red de n datos de entrenamiento seleccionados aleatoriamente, siendo n el número de registros que constituye el conjunto de datos de entrenamiento.

Cabe observar que, debido al carácter aleatorio del proceso de selección, puede que algunos registros de entrenamiento sean presentados más que una vez en determinados ciclos, mientras que otros puede que no lleguen a presentarse en absoluto.

D Determinación de las entradas/salidas de las neuronas y predicción de la red

Se calculan las salidas de cada una de las neuronas que componen la red. En cada iteración (que corresponde al procesamiento de un conjunto de registros) la información fluye a través de la red en sentido hacia adelante con el objetivo de generar una predicción (salida de la RNA). Las salidas se calculan de acuerdo a las funciones elegidas para cada capa de neuronas de la red. Tal y como sugieren Kong & Goo [56], se utiliza la función de activación tangente hiperbólica y la función identidad como funciones de transferencia para las capas ocultas y la capa de salida respectivamente. La tangente hiperbólica es una función que pertenece al grupo de las funciones sigmoideas, que suelen utilizarse para describir la evolución de los procesos de aprendizaje en sistemas complejos. En la [figura 12](#) se muestra la gráfica de la función tangente hiperbólica y de su derivada.




Figura 12. Gráficas de la función tangente hiperbólica y de su derivada.

Se puede observar una zona central alrededor del cero caracterizada por un elevado ritmo de aprendizaje, que luego evoluciona (a la izquierda y a la derecha del cero) hacia zonas periféricas de menor intensidad cognitiva, hasta establecerse en valores asintóticos que indican un estado de saturación de la neurona.

E Cálculo del error generado

Para cada conjunto de registros, se compara la predicción de la RNA con los datos de entrenamiento y se utiliza la diferencia calculada (error) para la fase sucesiva de propagación hacia atrás y actualización de los pesos sinápticos de la red.

F Ajuste de los pesos sinápticos

En esta fase el error calculado entre el valor deseado de la salida (registro) y la predicción del modelo es propagado en dirección hacia atrás por medio del “Algoritmo de Descenso por Gradiente con Momentum”, una técnica muy eficiente desde el punto de vista computacional que permite reducir al mínimo el error mediante la actualización de los pesos de conexión de la red.

Este método, que es el que se utiliza para el entrenamiento, es explicado de forma muy exhaustiva por Moghavvemi et al. [24] y por Hernández [119] y contempla el uso de dos coeficientes denominados factor de aprendizaje (η) y factor de momentum (m). Con el coeficiente η se controla el grado de modificación de los pesos en el algoritmo de entrenamiento, mientras que el momentum se utiliza para corregir la variación actual de los pesos con un término que refleja el impacto de los cambios anteriores en los pesos. El vector de los pesos sinápticos se actualiza mediante la fórmula

$$w_{k+1} = w_k - \eta_k g_k + m \Delta w_k \quad (8)$$

donde k indica el número de épocas y g es el gradiente de la función error $E(w)$ con respecto a los pesos, a su vez definida como

$$E(w) = \sum_{r=1}^{NR} E^{(r)}(w) \quad (9)$$

siendo

$$E^{(r)}(w) = \frac{1}{2} \sum_{n=1}^N \left(t_n^{(r)} - p_n^{(r)} \right)^2 \quad (10)$$

siendo

NR el número de registros;

N el número de salidas de la RNA;

t_n el valor objetivo de la salida n ;

p_n la predicción generada por la red correspondiente a t_n .

Para redes neuronales de una sola salida como son las entrenadas en este análisis ($N=1$), la fórmula para el cálculo del error puede simplificarse y describirse como

$$E(w) = \frac{1}{2} \sum_{r=1}^{NR} \left(t^{(r)} - p^{(r)} \right)^2 \quad (11)$$

Como se puede observar de la ecuación (8), el método del gradiente está basado en una aproximación lineal de la función error y la actualización de los pesos se efectúa en dirección contraria al gradiente calculado.

Del valor elegido para el factor de aprendizaje (η) depende tanto la rapidez como la efectividad del propio entrenamiento: si, por un lado, valores elevados de η suponen mayor rapidez en la minimización del error, por el otro lado aumentan los problemas de inestabilidad asociados a la mayor tendencia del error a las oscilaciones. Por el contrario, valores pequeños de η conllevan velocidades menores de convergencia, pero a la vez incrementa la capacidad de detección de mínimos del error sin que sean pasados por alto.

El momento m constituye una ayuda suplementaria para disminuir la inestabilidad y las oscilaciones del error. El momento introduce en el cálculo del error un término inercial que conserva la dependencia con la actualización de los pesos efectuada en el ciclo anterior. La función de este término es evitar que los pesos de la red no sean actualizados únicamente en función del gradiente local del error, sino que los cambios aplicados tengan en cuenta también las tendencias recientes de cambio en la función error. De esta forma, es como si en el algoritmo se introdujese un “filtro de paso bajo”, que elimina las pequeñas oscilaciones y evita que la búsqueda se quede estancada en mínimos locales.

Los autores de algunos de los trabajos encontrados en la revisión bibliográfica efectuada aplican valores fijos a los coeficientes η y m , planteándose así el problema de la optimización de dichos valores para maximizar la velocidad de convergencia y la calidad del resultado. En realidad, la selección de unos valores determinados e inmutables de estos factores para cada RNA entrenada supone imprecisión en el entrenamiento, ya a que es de esperar que los valores óptimos varíen al cambiar la función error y por lo tanto deberían mutar en cada iteración. Por esta razón, el algoritmo utilizado prevé el ajuste del factor de aprendizaje en cada iteración del

entrenamiento, lo cual reduce notablemente el tiempo necesario para la minimización del error.

A partir del valor inicial de η , que se ha fijado en 0,4 para todos los modelos entrenados, se aplica el método de variación dinámica del factor de aprendizaje propuesto por Liang-yu et al. [32] y Kong et al. [56]. Este método está basado en la aplicación de ajustes variables al factor de aprendizaje dependiendo de la evolución de la función error. Cuando el error decrece no se aplican correcciones, mientras que para aumentos del error se aplica una reducción significativa (factor de corrección 0,5), lo cual representa una modificación del algoritmo efectiva y fácil de implementar para incrementar la rapidez del proceso de entrenamiento.

El factor m se fija en 0,9 y se mantiene constante excepto en las situaciones en las cuales

$$\eta_k |g_k| \leq m |\Delta w_k| \quad (12)$$

En todos estos casos el valor m se recalcula y se fija en

$$m = 0.9 \eta_k \frac{|g_k|}{|\Delta w_k|} \quad (13)$$

asegurando de esta forma que los cambios aplicados a los pesos tienen lugar en la justa dirección cuando el error disminuye.

G Parada del entrenamiento

Las fases anteriores desde la C hasta la F se repiten de forma iterativa hasta cumplir una de las tres condiciones de parada del algoritmo antes comentadas:

- Se alcanza el nivel mínimo de precisión establecido.
- Se alcanza el número máximo de iteraciones establecido.
- Se manifiesta el fenómeno de sobre-ajuste del modelo.

6.4 Selección de la arquitectura final de las redes neuronales

La metodología de entrenamiento comentada en las secciones anteriores (fase 6.3) permite determinar el mejor ajuste de los pesos sinápticos de una RNA una vez que hayan sido fijados los demás parámetros que definen la estructura de la red: el número de capas ocultas y el número de neuronas en cada capa. Se plantea por lo tanto la necesidad de establecer una metodología que permita también la optimización de estos parámetros, siempre con el objetivo de maximizar la precisión de reproducción de un conjunto conocido de datos. El método propuesto para la determinación del número de capas y de neuronas de las RNA se compone de dos fases principales, que se detallan a continuación.

A Entrenamiento de redes monocapa

En una fase preliminar del proceso de entrenamiento se realizaron una serie de entrenamientos dirigidos a determinar las prestaciones de redes neuronales del tipo monocapa con número creciente de neuronas, desde 1 hasta 15, que fue fijado como el límite máximo de neuronas para el análisis. No se considera necesario incrementar ulteriormente el nivel de complejidad de las RNA, ya que está comprobado que un número excesivo de neuronas puede favorecer el sobre-ajuste de la RNA en lugar de producir efectos beneficiosos, reduciendo a la vez la capacidad de generalización de la red [74].

B Introducción de la segunda capa oculta

Sucesivamente se procedió a la selección de las RNA monocapa previamente entrenadas que presentaban máximos locales en la capacidad de predicción y se observaron los efectos de la introducción de una segunda capa oculta de neuronas. El número de neuronas de la segunda capa fue aumentado progresivamente para cada una de las RNA seleccionadas, desde 1 hasta el mismo número de neuronas de la primera capa oculta.

En el caso de observarse mejoras con la segunda capa oculta, se selecciona la RNA con mejor capacidad de predicción entre las redes entrenadas de doble capa. De lo contrario, se utiliza la red monocapa con mejor poder predictivo, priorizándose la simplicidad y manejabilidad de la red ante un mismo nivel de precisión.

6.5 Determinación de las prestaciones del modelo

En esta fase se evalúa la precisión de los modelos y su capacidad de reproducción del conjunto de registros de test seleccionados durante el proceso de entrenamiento.

De acuerdo a la metodología propuesta para la selección de la arquitectura final de los modelos, se determinan las prestaciones de los modelos para cada una de las RNA entrenadas en el curso de dicha selección. Por esta razón la fase 6.5 se aplica para cada red neuronal entrenada en la fase 6.4, ya que la selección final de los modelos definitivos se efectúa una vez que hayan sido comparados entre ellos los niveles de precisión alcanzados por cada modelo.

6.5.1 Criterio de evaluación

El criterio principal que ha sido utilizado para evaluar las prestaciones de las RNA entrenadas está basado en el coeficiente de precisión definido por la fórmula

$$\text{Precisión} = \frac{1}{NR} \sum_{r=1}^{NR} \left(1 - \frac{|t_r - p_r|}{\max_i(t_i) - \min_i(t_i)} \right) \quad (14)$$

siendo

NR el número de registros;

t_r el valor del registro r (valor objetivo);

p_r la predicción generada por la red neuronal correspondiente a t_r ;

$\max(t_i)$ y $\min(t_i)$ los valores máximo y mínimo entre todos los registros (el subíndice i se utiliza para indicar que no varían con el índice r).

Para disponer de una información más completa que permita un enjuiciamiento más exhaustivo de la capacidad de predicción de los modelos, en paralelo al coeficiente de precisión se ha procedido al cálculo de los siguientes coeficientes:

- Error absoluto medio (MAE - mean absolute error)

$$MAE = \frac{1}{NR} \sum_{r=1}^{NR} \left| \frac{t_r - p_r}{t_r} \right| \quad (15)$$

- Error cuadrático medio (RMSE - root mean square error)

$$RMSE = \sqrt{\frac{1}{NR} \sum_{r=1}^{NR} \left(\frac{t_r - p_r}{t_r} \right)^2} \quad (16)$$

- Coeficiente de determinación R^2 , que es el cuadrado del coeficiente de Pearson de correlación del producto-momento R , a su vez definido como

$$R = \frac{\sum_{r=1}^{NR} (t_r - \bar{t})(p_r - \bar{p})}{\sqrt{\sum_{r=1}^{NR} (t_r - \bar{t})^2} \cdot \sqrt{\sum_{r=1}^{NR} (p_r - \bar{p})^2}} \quad (17)$$

6.5.2 Capacidad de predicción de los modelos RNA

Con el objetivo de comprobar el potencial de aprendizaje de las RNA y validar su poder de captación de los patrones de comportamiento del sistema, se cuantifican los niveles de precisión asociados a los modelos obtenidos de la aplicación de las [fases 6.4](#) y [6.5](#) a la planta de cogeneración.

El período de referencia elegido para el modelado y la validación de los modelos ha sido definido en la [fase 4](#), así como las operaciones de filtrado efectuadas, tras las cuales el conjunto de datos disponibles para el entrenamiento de los modelos relativos a la turbina de gas se compone de 6.405 registros.

Tras proceder a la aleatorización previa de los datos, los 6.405 registros fueron agrupados en dos conjuntos principales:

- El 70% de los datos se utilizaron para el entrenamiento.
- El 30% restante se utilizó como conjunto de test para evaluar la capacidad de predicción de las RNA en cada época de entrenamiento.

De acuerdo a cuanto comentado anteriormente, el conjunto de datos de entrenamiento fue dividido ulteriormente en dos subconjuntos:

- ✓ Subconjunto de construcción del modelo: 85% de los datos de entrenamiento, que corresponde al 59,5% del total de los datos.

- ✓ Subconjunto de validación cruzada, siendo este último necesario para evitar el fenómeno de sobre-ajuste de la red: 15% de los datos de entrenamiento, que corresponde al 10,5% del total de registros.

En la [tabla 6](#) se indican los valores de precisión obtenidos en el proceso de selección de la estructura final del modelo RNA para la generación eléctrica de la turbina de gas.

El carácter limitado de las variaciones calculadas para la capacidad de predicción de los modelos confirma el escaso nivel de influencia de los cambios en el número de neuronas en las capas ocultas sobre dicha capacidad. Esta tendencia ya fue observada por otros autores y es típica para aplicaciones en las cuales se realiza el modelado de series de datos afectos por errores de medición [58]. En la tabla pueden observarse máximos locales de precisión para 3, 6 y 8 neuronas en la primera capa oculta. La máxima precisión se obtiene con 8 neuronas y no se aprecian mejoras aumentando las neuronas de la primera capa. Por esta razón, las estructuras con 3, 6 y 8 neuronas se seleccionan para analizar los efectos de la introducción de una segunda capa oculta de neuronas. Como puede verse de los valores mostrados, la segunda capa no tiene efectos positivos sobre la estructura de 3 neuronas, mientras que se observan ligeros beneficios en algunos casos para las estructuras de 6 y 8 neuronas. La configuración final seleccionada contiene 8 neuronas en la primera capa y 3 neuronas en la segunda capa oculta.

En la [tabla 7](#) se muestran los mismos resultados, obtenidos para el modelado del consumo de combustible en la turbina de gas.

Los niveles de precisión calculados son muy inferiores a los obtenidos para la generación eléctrica de la turbina de gas. Eso se debe al mayor nivel de error que afecta a las mediciones, principalmente asociado a los análisis de poder calorífico del combustible, llevados a cabo de forma diaria en la planta. En este sentido, se considera que a partir de 9 neuronas existe el peligro de que el aumento de precisión incluya la reproducción por parte del modelo de los "ruidos" presentes en los datos, y por ello se descartan las estructuras con número de neuronas superior a 9 en la primera capa. Se selecciona como configuración definitiva para el modelo la 7-2, por representar un buen compromiso entre complejidad de la estructura y nivel de precisión obtenido. Se destaca que existen estructuras más complejas que conllevan asociados niveles mayores de precisión (10-9, 14-9, 14-12, 14-13, 14-14), pero se descartan por las razones antes comentadas.

El mismo análisis fue llevado a cabo para los tres demás parámetros objeto de modelado, con el objetivo de determinar la estructura definitiva de las RNA para la generación de las líneas base de consumo y generación del sistema.

La [tabla 8](#) resume las estructuras finales elegidas, la distribución del error y la capacidad de predicción obtenida para todos los modelos RNA generados.

En las [figuras 13-17](#) se muestran las prestaciones de los modelos definitivos elegidos para los cinco parámetros modelados, en términos de diferencias entre predicciones y registros, sobre todo el período de validación.

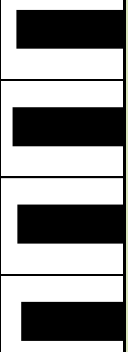
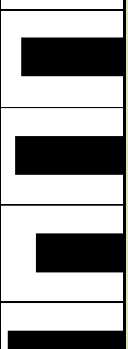
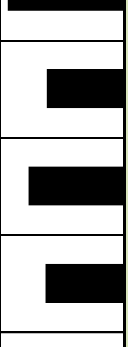
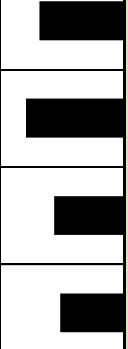

Generación eléctrica TG															
Estructura monocapa hacia adelante (feed-forward)															
Nº neuronas en la primera capa oculta	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Precisión obtenida (%)	94,557	94,715	95,400	95,070	94,912	95,330	94,880	95,837	95,150	95,663	95,523	95,524	95,605	95,722	95,620
															
Estructura de doble capa hacia adelante (feed-forward)															
Nº neuronas en la primera-segunda capa oculta	3-1	3-2	3-3												
Precisión obtenida (%)	94,768	95,399	95,341												
Nº neuronas en la primera-segunda capa oculta	6-1	6-2	6-3	6-4	6-5	6-6									
Precisión obtenida (%)	95,150	95,268	95,493	95,393	95,495	95,485									
Nº neuronas en la primera-segunda capa oculta	8-1	8-2	8-3	8-4	8-5	8-6	8-7	8-8							
Precisión obtenida (%)	95,310	95,532	95,850	95,338	95,508	95,254	95,091	95,600							

Tabla 6. Selección de la estructura RNA para el modelado de la generación eléctrica de la turbina de gas. Precisión obtenida.
















Consumo de combustible TG															
Estructura monocapa hacia adelante (feed-forward)															
Nº neuronas en la primera capa oculta	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Precisión obtenida (%)	92,628	92,819	93,049	92,646	93,110	93,188	93,246	92,973	92,974	93,327	93,219	93,240	93,246	93,313	93,211
															
Estructura de doble capa hacia adelante (feed-forward)															
Nº neuronas en la primera-segunda capa oculta	7-1	7-2	7-3	7-4	7-5	7-6	7-7								
Precisión obtenida (%)	93,002	93,294	92,967	92,965	93,099	93,130	93,067								
Nº neuronas en la primera-segunda capa oculta	10-1	10-2	10-3	10-4	10-5	10-6	10-7	10-8	10-9	10-10					
Precisión obtenida (%)	93,202	93,194	93,092	93,238	93,146	93,161	93,205	93,043	93,314	93,296					
Nº neuronas en la primera-segunda capa oculta	14-1	14-2	14-3	14-4	14-5	14-6	14-7	14-8	14-9	14-10	14-11	14-12	14-13	14-14	
Precisión obtenida (%)	93,294	93,123	93,231	93,102	93,278	93,125	93,292	92,964	93,326	93,280	93,231	93,316	93,486	93,403	

Tabla 7. Selección de la estructura RNA para el modelado del consumo de combustible de la turbina de gas. Precisión obtenida.

Parámetro modelado	Nº entradas	Nº neuronas en la primera capa oculta	Nº neuronas en la segunda capa oculta	Distribución del error (% sobre el total)							MAE (%)	RMSE (%)	R ²	Precisión (%)
				0,1%	0,1÷0,5%	0,5÷1,0%	1,0÷2,0%	2,0÷5,0%	5,0÷10,0%	Superior a 10,0%				
Generación eléctrica TG	7	8	3	13,5	45,8	29,3	10,5	0,9	0,0	0,0	0,51	0,67	0,95	95,85
Consumo de combustible TG	7	7	2	6,6	24,5	26	28,4	14,1	0,4	0,0	1,08	1,41	0,74	93,29
Inyección de vapor MP en la TG	6	12	5	2,2	9,7	11,2	20,8	35,9	17,4	2,8	3,16	4,32	0,94	96,90
Consumo vapor BP en desgasificador	4	3	/	3,1	11,5	15,2	25,0	34,6	8,7	1,9	2,45	3,58	0,94	97,22
Consumo de combustible post-combustión	7	14	7	7,4	30,9	28,2	25,5	6,7	0,5	0,8	1,05	2,80	0,44	91,46 ⁽¹⁾

⁽¹⁾ Según la definición de Precisión, el cálculo debería realizarse incluyendo al denominador de la fórmula la diferencia entre los valores máximo y mínimo registrados. No obstante, para este caso, para obtener un valor más representativo de la capacidad de predicción, dicha diferencia se ha reducido hasta un valor que refleje las variaciones reales del consumo de combustible en post-combustión, sin tener en cuenta las fluctuaciones excesivas.

Tabla 8. Estructura final y capacidad de predicción de los modelos RNA generados.

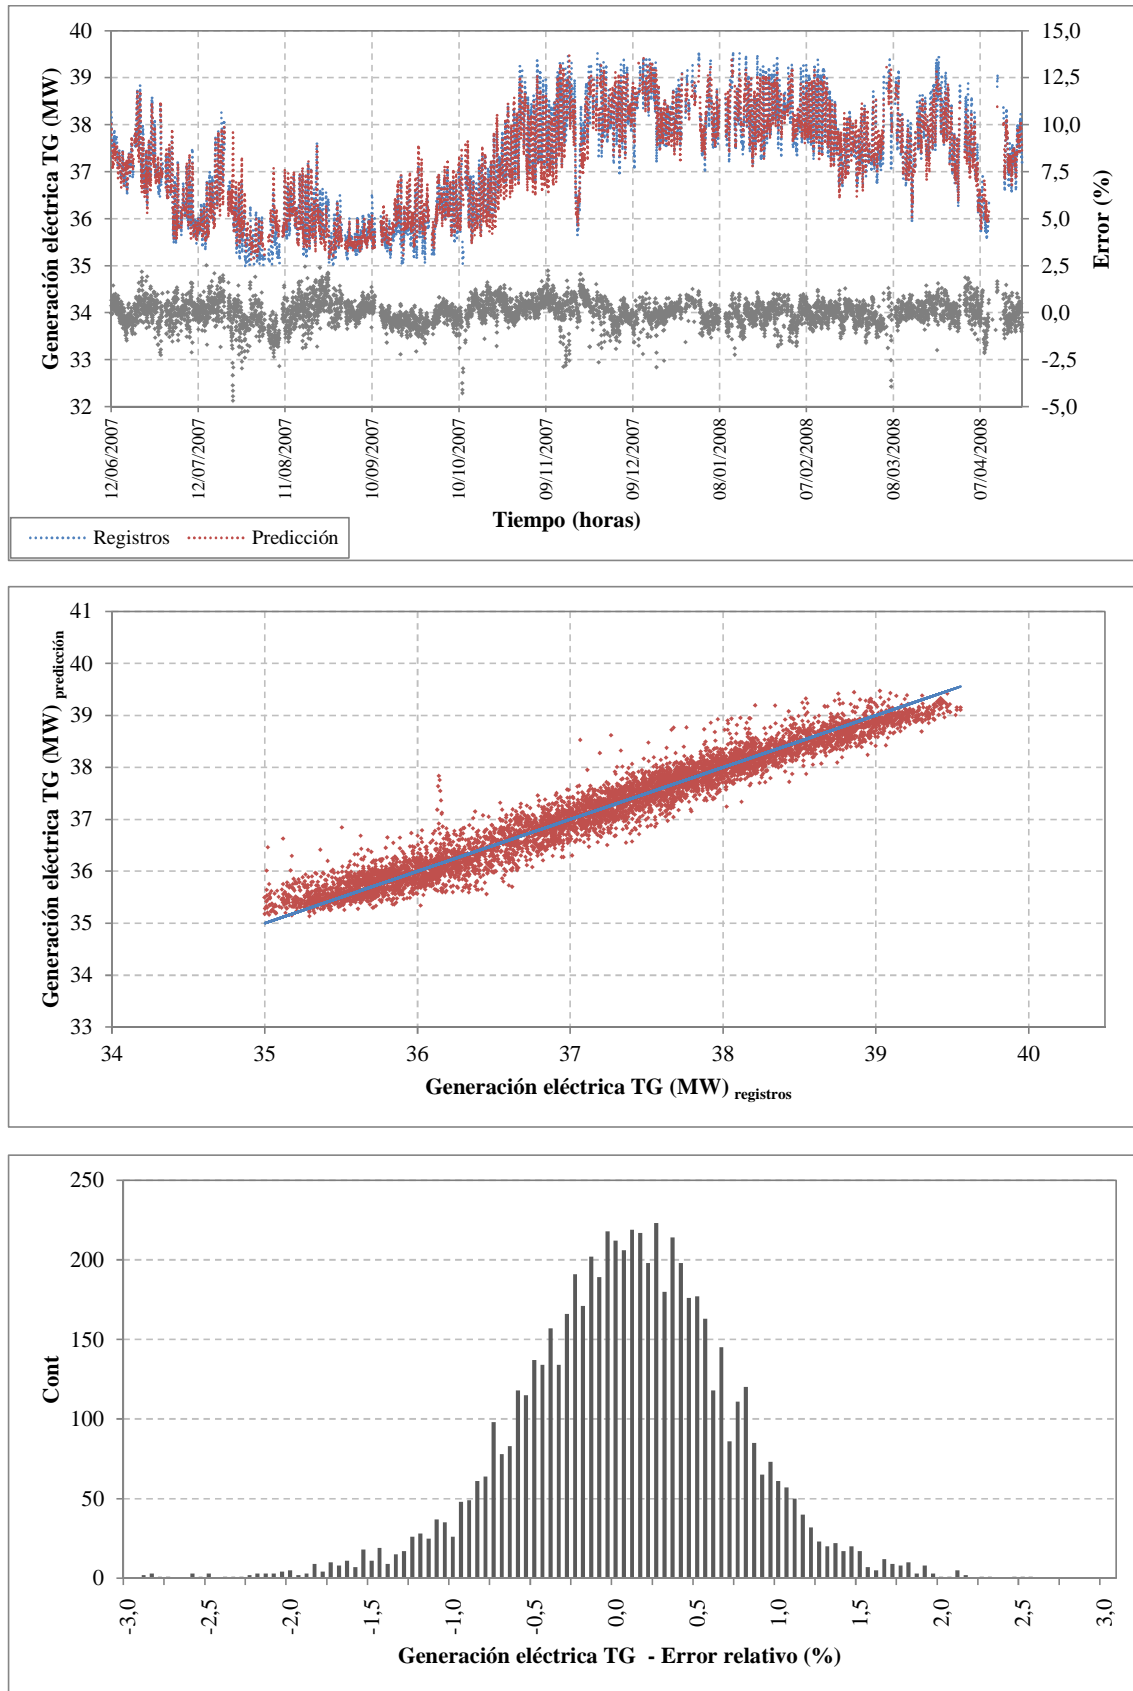


Figura 13. Modelo RNA de la generación eléctrica en turbina de gas. Predicciones, registros y errores en el período de validación.

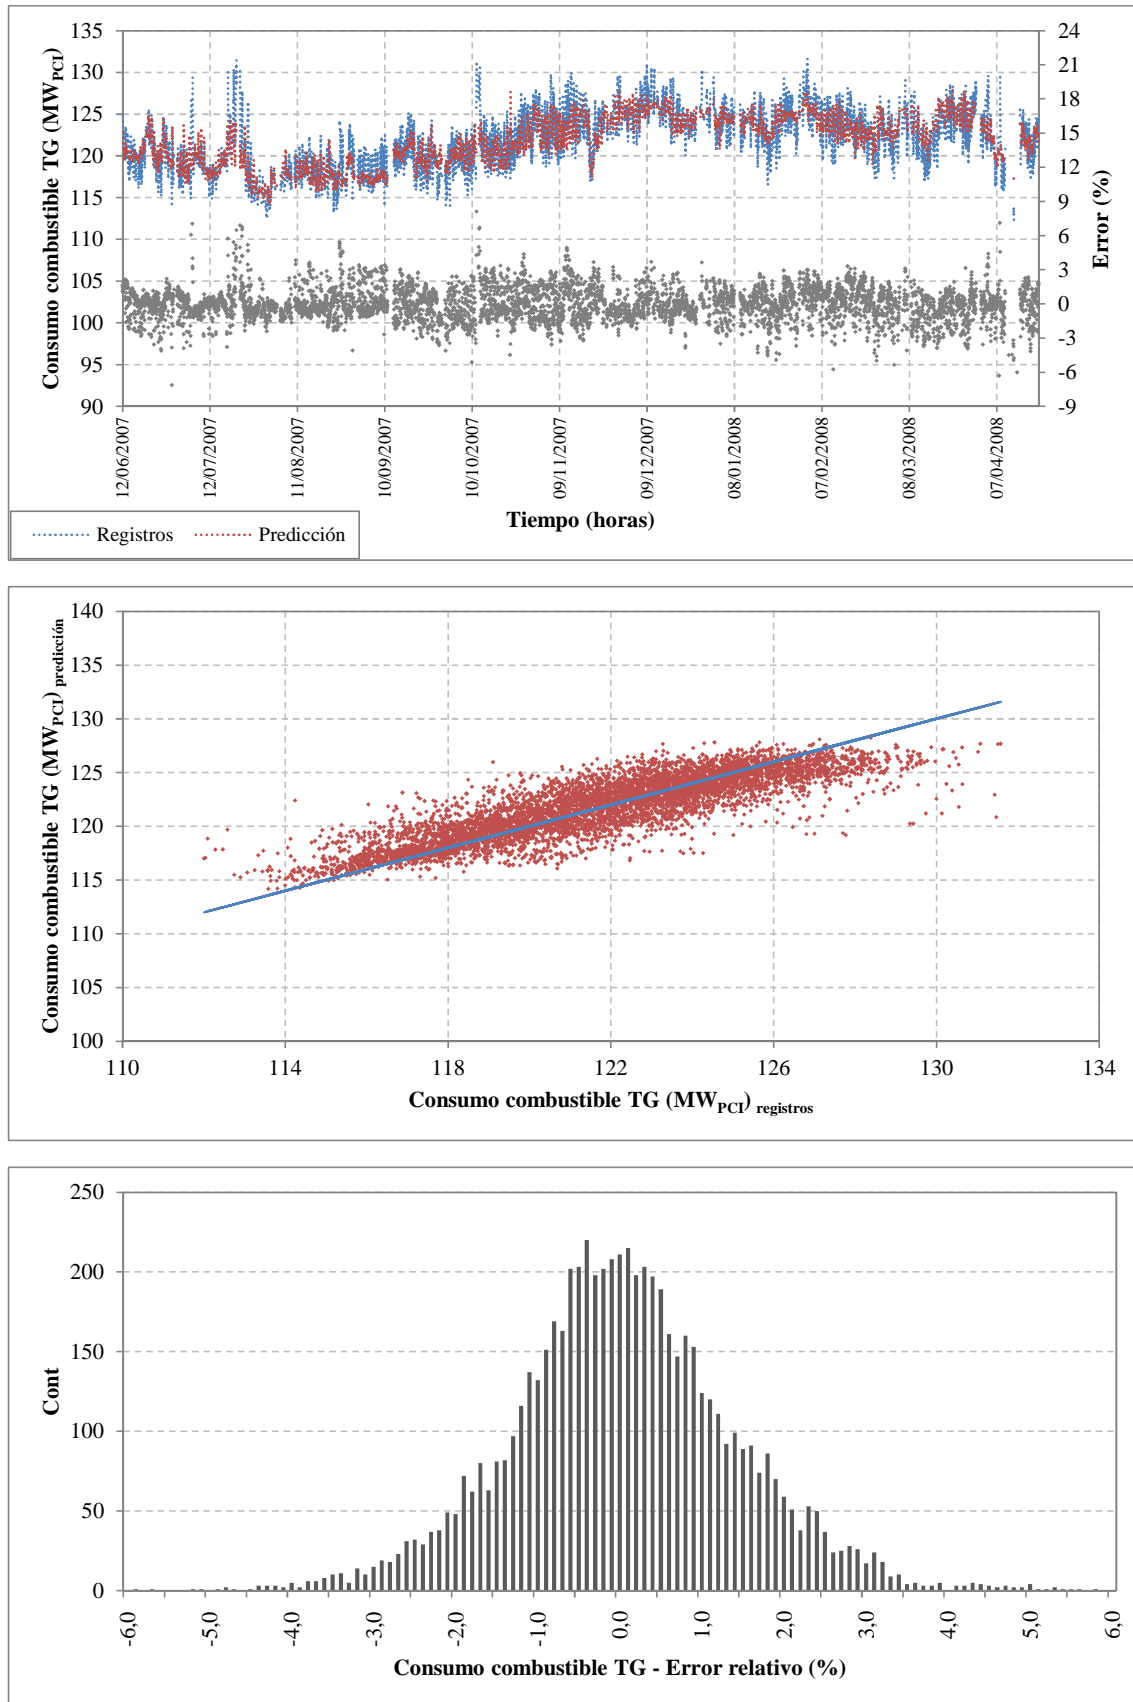


Figura 14. Modelo RNA del consumo combustible en turbina de gas. Predicciones, registros y errores en el período de validación.

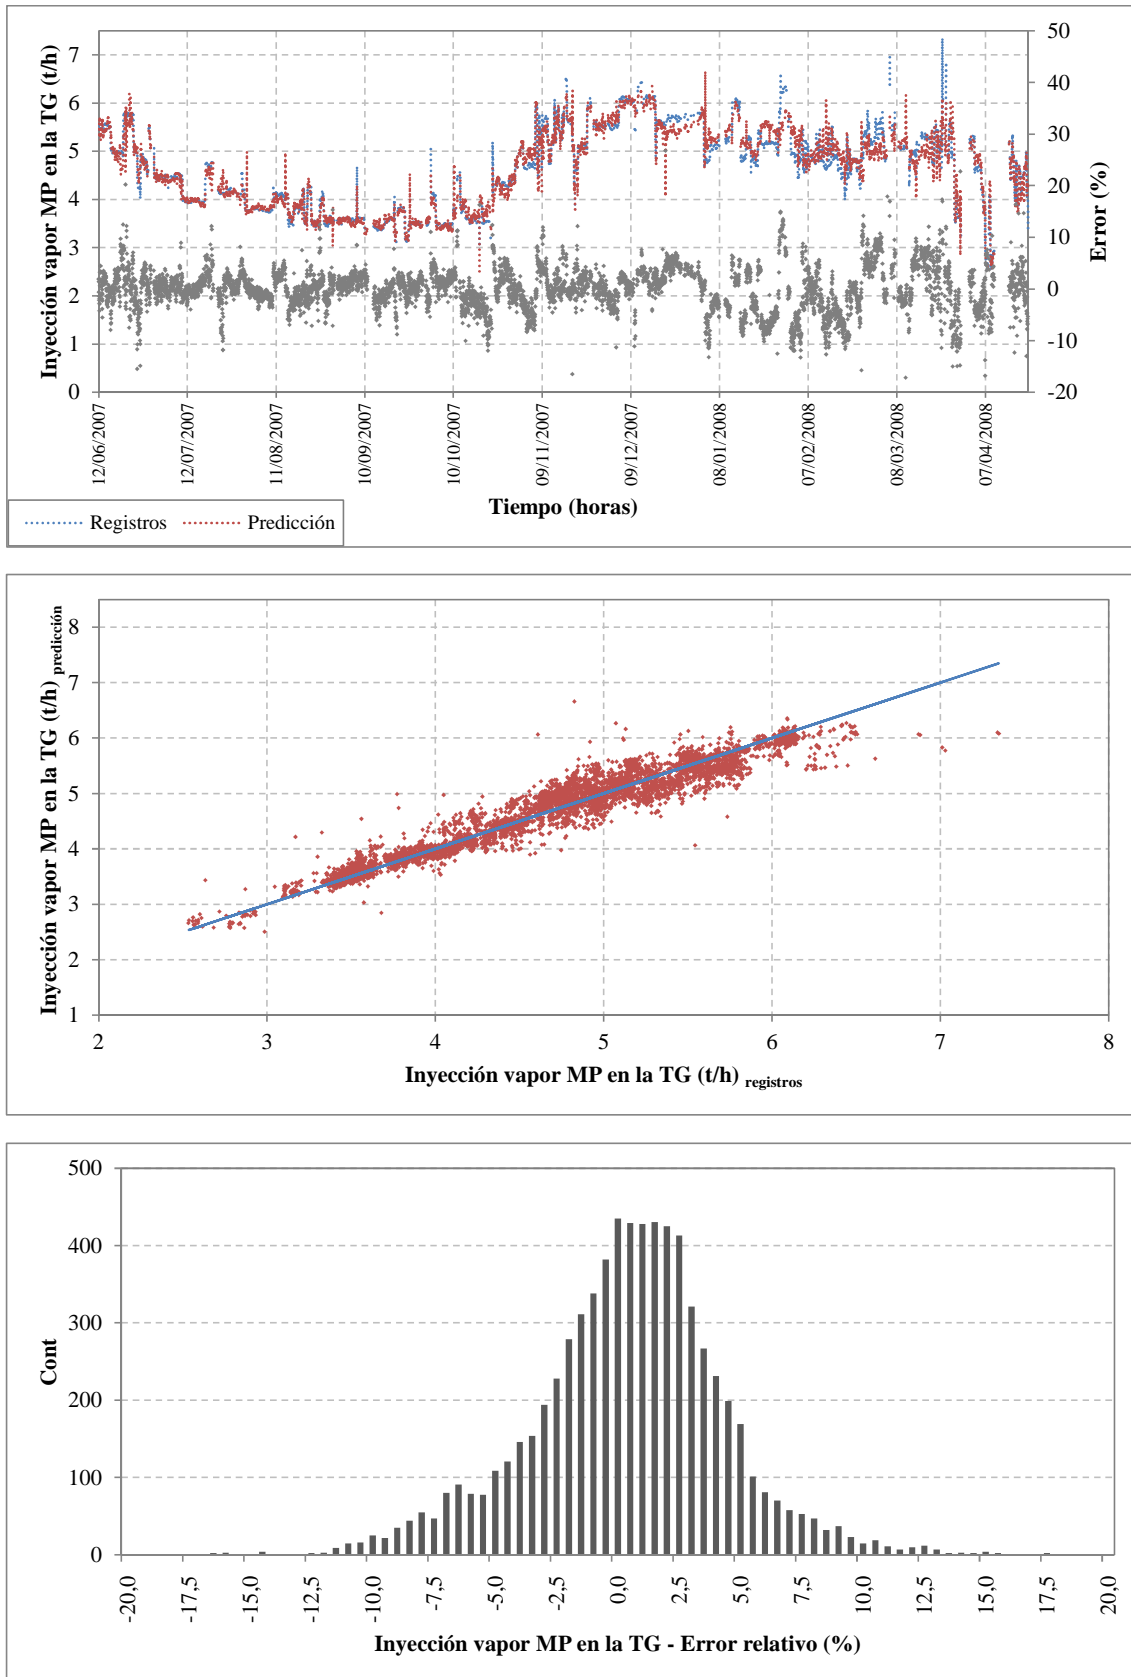


Figura 15. Modelo RNA de la inyección de vapor en turbina de gas. Predicciones, registros y errores en el periodo de validación.

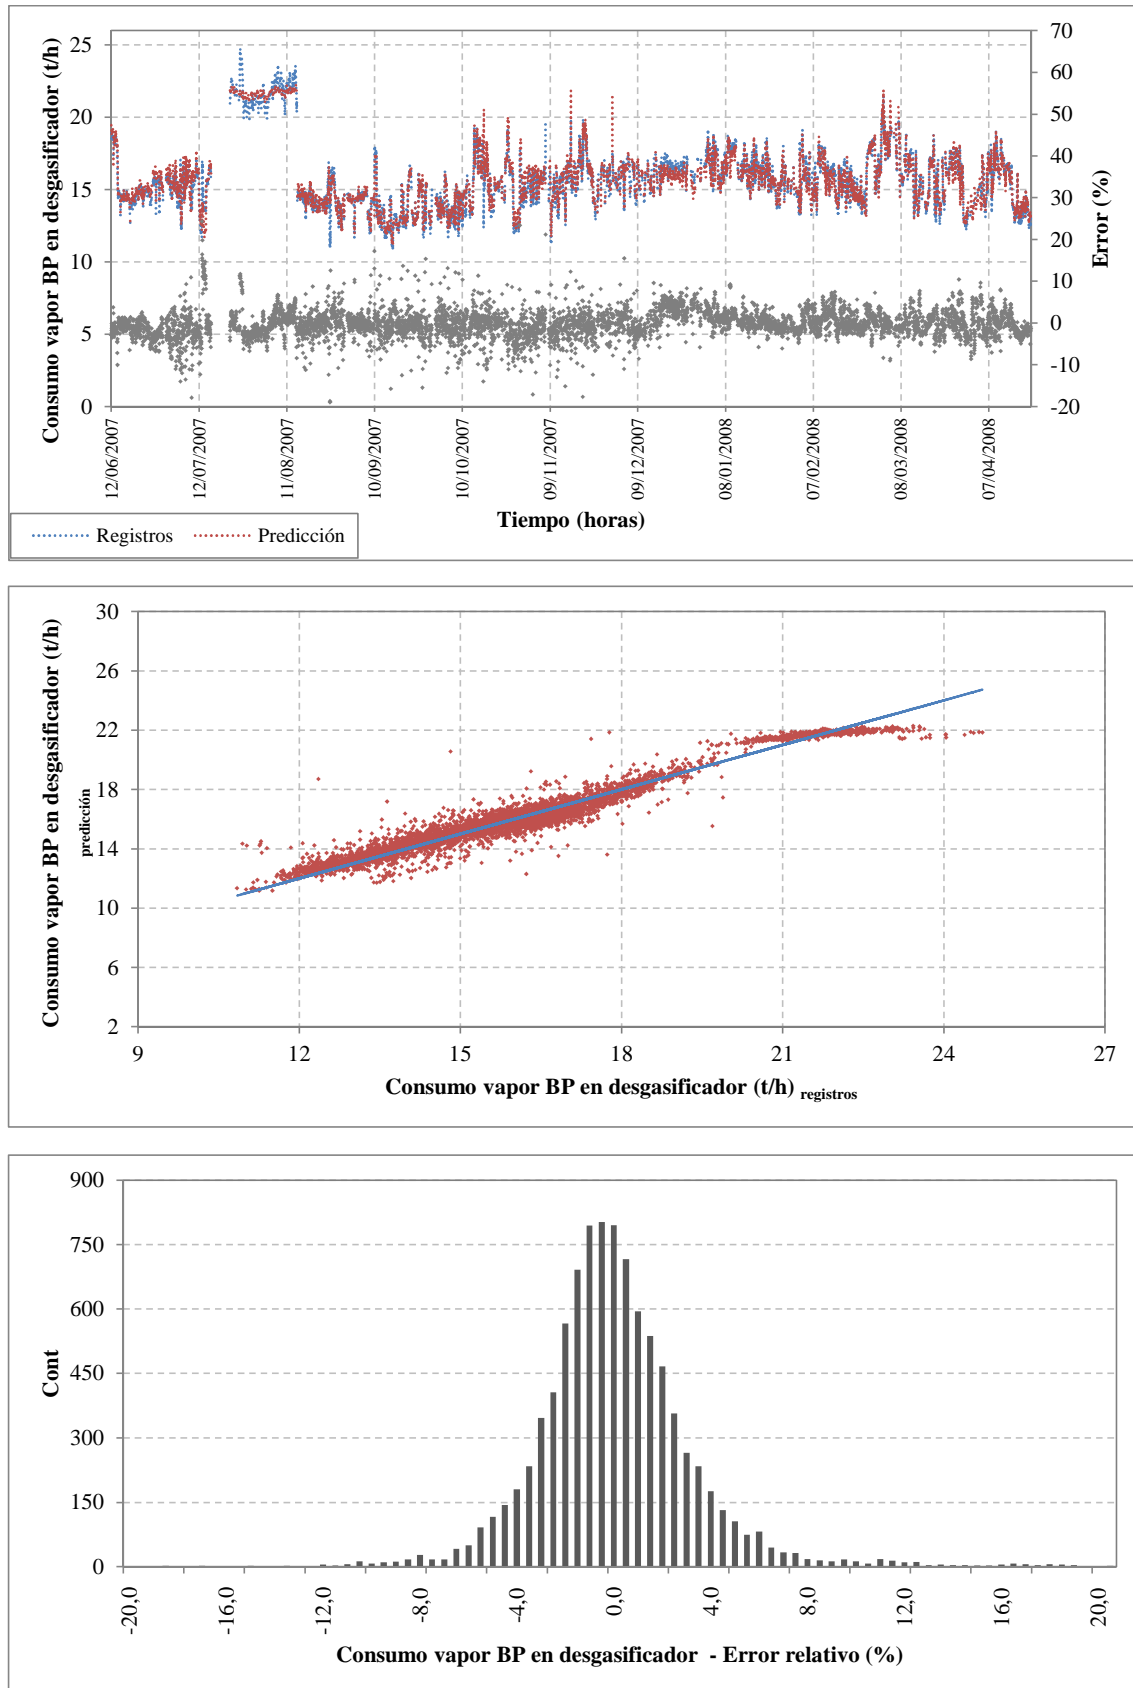


Figura 16. Modelo RNA del consumo de vapor en el desgasificador. Predicciones, registros y errores en el período de validación.

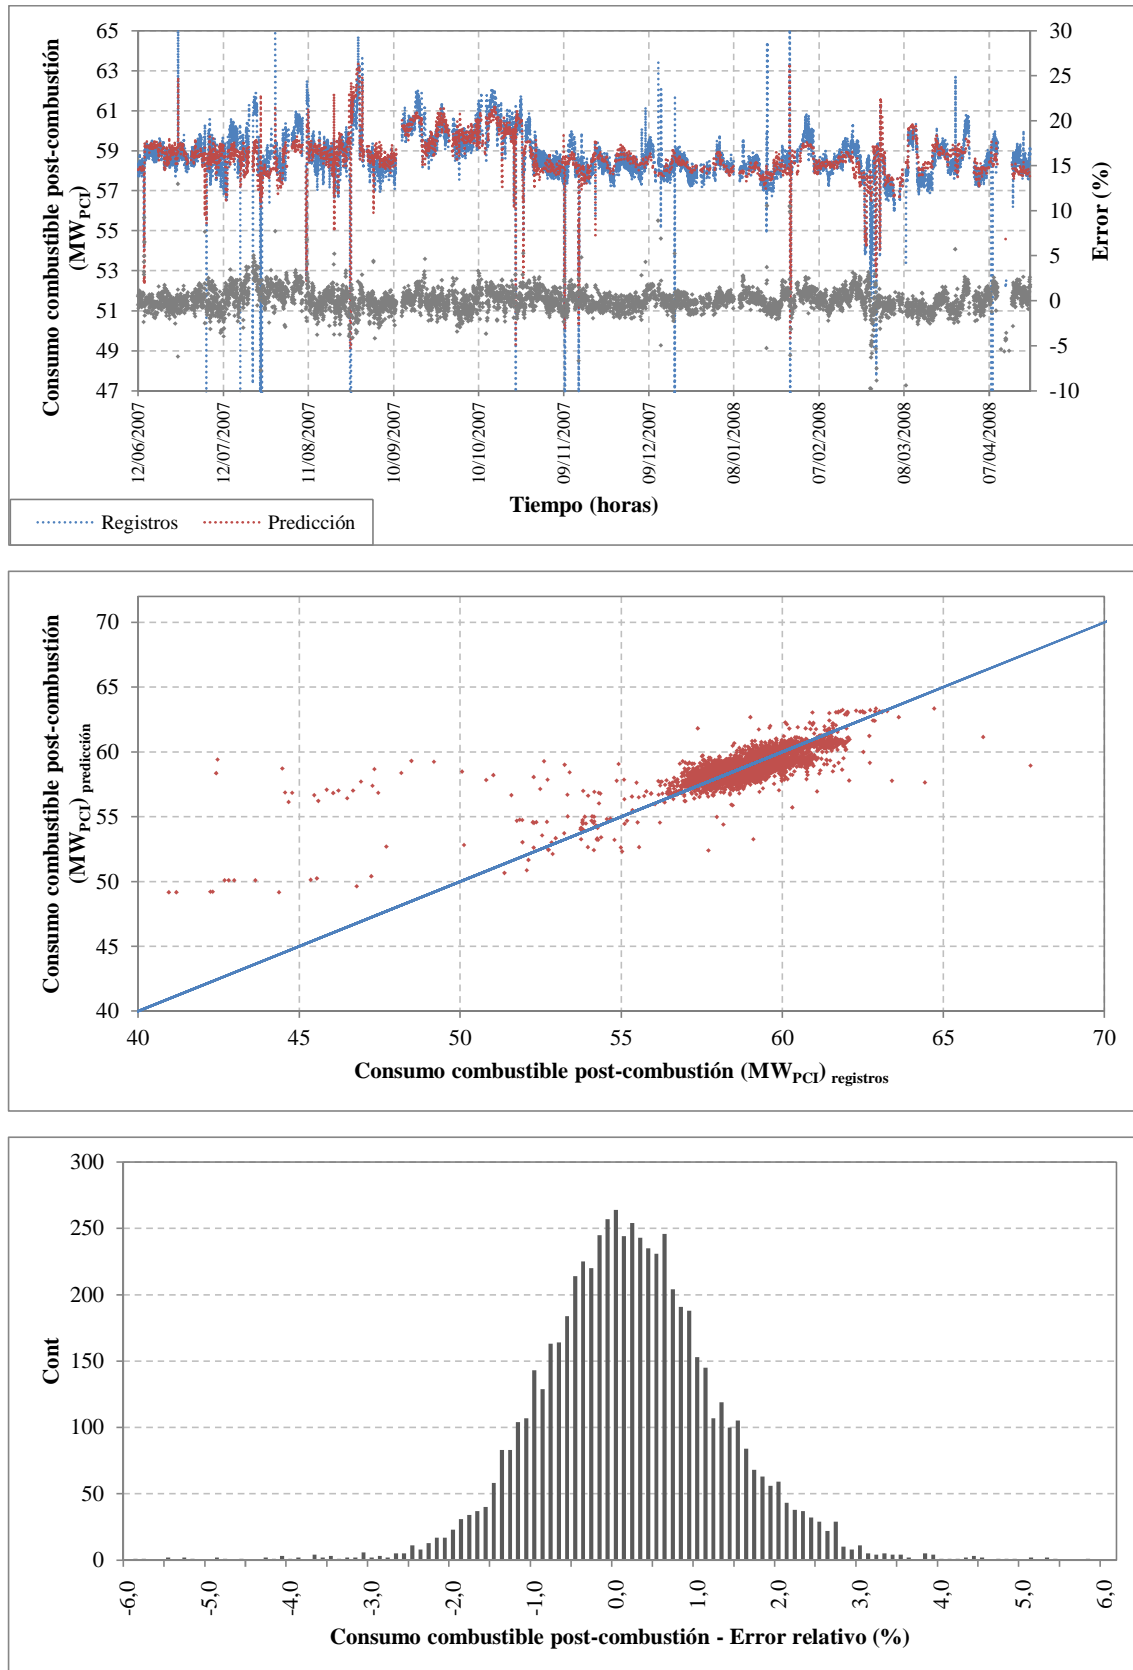


Figura 17. Modelo RNA del consumo de combustible en post-combustión. Predicciones, registros y errores en el período de validación.

En la primera de las tres gráficas de las [figuras 13, 14, 15, 16, 17](#) se representan simultáneamente las predicciones de las RNA y los registros, junto con el error calculado para cada hora de operación. La segunda gráfica contiene la misma información, pero en forma de diagrama cruzado de los valores predichos frente a los medidos. La tercera gráfica representa la distribución de los errores relativos alrededor del cero.

En general, desde las primeras gráficas se puede observar un nivel satisfactorio de correspondencia entre valores reales y predichos. Asimismo en las segundas gráficas se aprecia una tendencia aleatoria y por lo tanto correcta (ya que no se detecta comportamiento sistemático) de las desviaciones de la diagonal.

En el caso del consumo de vapor en el desgasificador, se observa una fuerte tendencia nivelante por parte del modelo en la zona de altos valores de caudal. Eso se debe principalmente al número exiguo de datos disponibles para el entrenamiento del modelo en ese período, que no refleja la operación usual de la planta: la configuración de la cogeneración en el período anterior al retrofit incluye un intercambiador de calor para el precalentamiento del agua de alimentación al desgasificador mediante los condensados retornados de la refinería. Durante el período en cuestión – en el cual el modelo presenta precisión reducida – el intercambiador no estaba recibiendo condensados, lo cual explica el aumento de consumo de vapor en el desgasificador. Al margen de estas consideraciones, se observa que los errores relativos calculados en esta zona son todavía aceptables y su orden de magnitud es el mismo de los obtenidos en el resto del período de modelado y validación.

En las [figuras 18-22](#) se muestran los mismos resultados, pero para un período de tiempo mucho más limitado (dos semanas), de forma que pueda apreciarse con mayor detalle el comportamiento de los modelos frente a las series de registros.




Figura 18. Modelo RNA de la generación eléctrica en turbina de gas. Predicciones y registros. Resultados para un período de dos semanas.




Figura 19. Modelo RNA del consumo combustible en turbina de gas. Predicciones y registros. Resultados para un período de dos semanas.




Figura 20. Modelo RNA de la inyección de vapor en turbina de gas. Predicciones y registros. Resultados para un período de dos semanas.




Figura 21. Modelo RNA del consumo de vapor en el degasificador. Predicciones y registros. Resultados para un período de dos semanas.




Figura 22. Modelo RNA del consumo de combustible en post-combustión. Predicciones y registros. Resultados para un período de dos semanas.

Se destaca el alto nivel de significatividad de estos diagramas, ya que representan la transposición gráfica de los valores de precisión y de R^2 calculados y resumidos en la [tabla 8](#), en términos de capacidad de los modelos de reproducir los perfiles de datos medidos, y más concretamente de flexibilidad y habilidad de seguimiento de las tendencias y fluctuaciones en los registros.

En este sentido, para la generación eléctrica de la turbina de gas los valores de los índices de prestación indicados en la [tabla 8](#) son satisfactorios, lo cual queda confirmado por la excelente capacidad del modelo de reproducción de los registros observable en las [figuras 13 y 18](#). Casi el 89% de los puntos presenta errores inferiores al 1,0% y sólo el 0,9% son superiores al 2,0%.

Como se ha comentado anteriormente, para el consumo de combustible de la turbina de gas el nivel de precisión obtenido es inferior. La tendencia del modelo a nivelar las fluctuaciones de los registros puede observarse tanto en los diagramas generados ([figuras 14 y 19](#)) como en el bajo valor calculado para R^2 . La causa principal de este comportamiento reside en la calidad de los datos utilizados para el entrenamiento, y más precisamente en la frecuencia de adquisición de los registros empleados en el cálculo de la potencia térmica consumida: el caudal de combustible es medido en base horaria, mientras que los datos de poder calorífico proceden de análisis diarios de laboratorio, que impiden apreciar sus oscilaciones horarias. Por esta razón se puede afirmar que las fluctuaciones de los registros no son representativas de la operación real de la turbina de gas y, en este sentido, es de valorar la utilidad del modelo como filtro a dichas inestabilidades. Independientemente de estas consideraciones, la capacidad de predicción del modelo puede considerarse aceptable, al ser casi el 86% de los errores calculados inferiores al 2,0% y sólo el 0,4% de ellos superiores al 5,0%.

Las mismas consideraciones se aplican al caso de la potencia térmica quemada en la post-combustión. Para este caso se destaca el carácter aún más marcado de la tendencia nivelante del modelo, reflejado en el bajo valor calculado para R^2 , sin que todavía se vea afectada excesivamente la precisión global obtenida.

Los modelos generados para la inyección de vapor en la turbina de gas y el consumo de vapor en el desgasificador reproducen correctamente las tendencias de los registros, como confirman los valores calculados de R^2 y precisión. Como era de esperarse, para estos dos modelos se obtienen valores más elevados de MAE y RMSE, debido principalmente a los niveles relevantes de error que suelen estar asociados con las mediciones de caudales de vapor. Mediamente el 85% de los errores son inferiores a 5,0% para estos dos modelos.

A la luz de los errores y precisiones obtenidas, se puede concluir que los modelos generados capturan de forma correcta los patrones de comportamiento de la planta de cogeneración. La capacidad de predicción puede considerarse satisfactoria de cara al objetivo de dichos modelos, que es la generación de las líneas base de consumo y generación de energía, ya que el orden de magnitud de los errores obtenidos con los modelos es el mismo que caracteriza la incertidumbre asociada a los instrumentos de medición correspondientes.

6.6 Modelado termodinámico (opcional)

Tras haber entrenado y evaluado el nivel de precisión de las RNA, se contrastan las prestaciones de estos modelos predictivos comparándolas con las que se obtienen del modelado termodinámico del sistema. Esta forma de proceder responde a la necesidad de disponer de una referencia en base a la cual poder comprobar las capacidades de los modelos estadísticos obtenidos, así como de conferir robustez a los resultados obtenidos a través de su comparación con la técnica de simulación termodinámica, cuyo potencial y rigor de reproducción del comportamiento de los sistemas energéticos están más que comprobados.

Cabe indicar que esta fase del estudio se aplica al caso concreto de la planta de cogeneración analizada, pero con el objetivo de que no se tenga que volver a ejecutar en los estudios futuros inspirados a la metodología propuesta. De hecho está entre los objetivos del trabajo propuesto demostrar el potencial de los modelos RNA para solucionar el problema de la línea base de consumo energético, así como comprobar la validez de su aplicación en sustitución a las técnicas más convencionales de modelado termodinámico. De acuerdo a estas consideraciones, la [fase 6.6](#) no ha de considerarse indispensable dentro de la metodología propuesta, sino que se deja como opcional tal y como indica el título de esta sección.

El modelo de la planta de cogeneración fue desarrollado utilizando el simulador Thermoflex versión 23.0 [\[120\]](#), un software específico para la simulación de sistemas térmicos especialmente concebido para plantas de potencia incluyendo ciclos combinados y ciclos convencionales de vapor.

6.6.1 Descripción del modelo

El modelo generado reproduce la planta de cogeneración en su configuración previa a la implantación de las MAE. En la [figura 23](#) se muestra el esquema utilizado para la simulación.

Como se puede observar, la turbina de vapor no fue incluida en el modelo, debido a que su operación y generación eléctrica no se vieron afectadas por las MAE: tal y como se ha comentado en las secciones anteriores, el desacoplamiento existente entre la turbina de gas y la caldera de recuperación asociado a la presencia del quemador de post-combustión hizo que la reducción de potencia térmica contenida en los gases de escape de la turbina de gas no afectara a las propiedades del vapor vivo a la entrada de la turbina de vapor. Asimismo, se recuerda que el aumento de exportación de vapor de MP y BP no tuvo repercusiones sobre la estrategia de control de la turbina de vapor, ya que ese incremento fue absorbido totalmente por el proceso, sin que se registraran excesos y consecuentes venteos en los colectores de vapor de MP y BP.

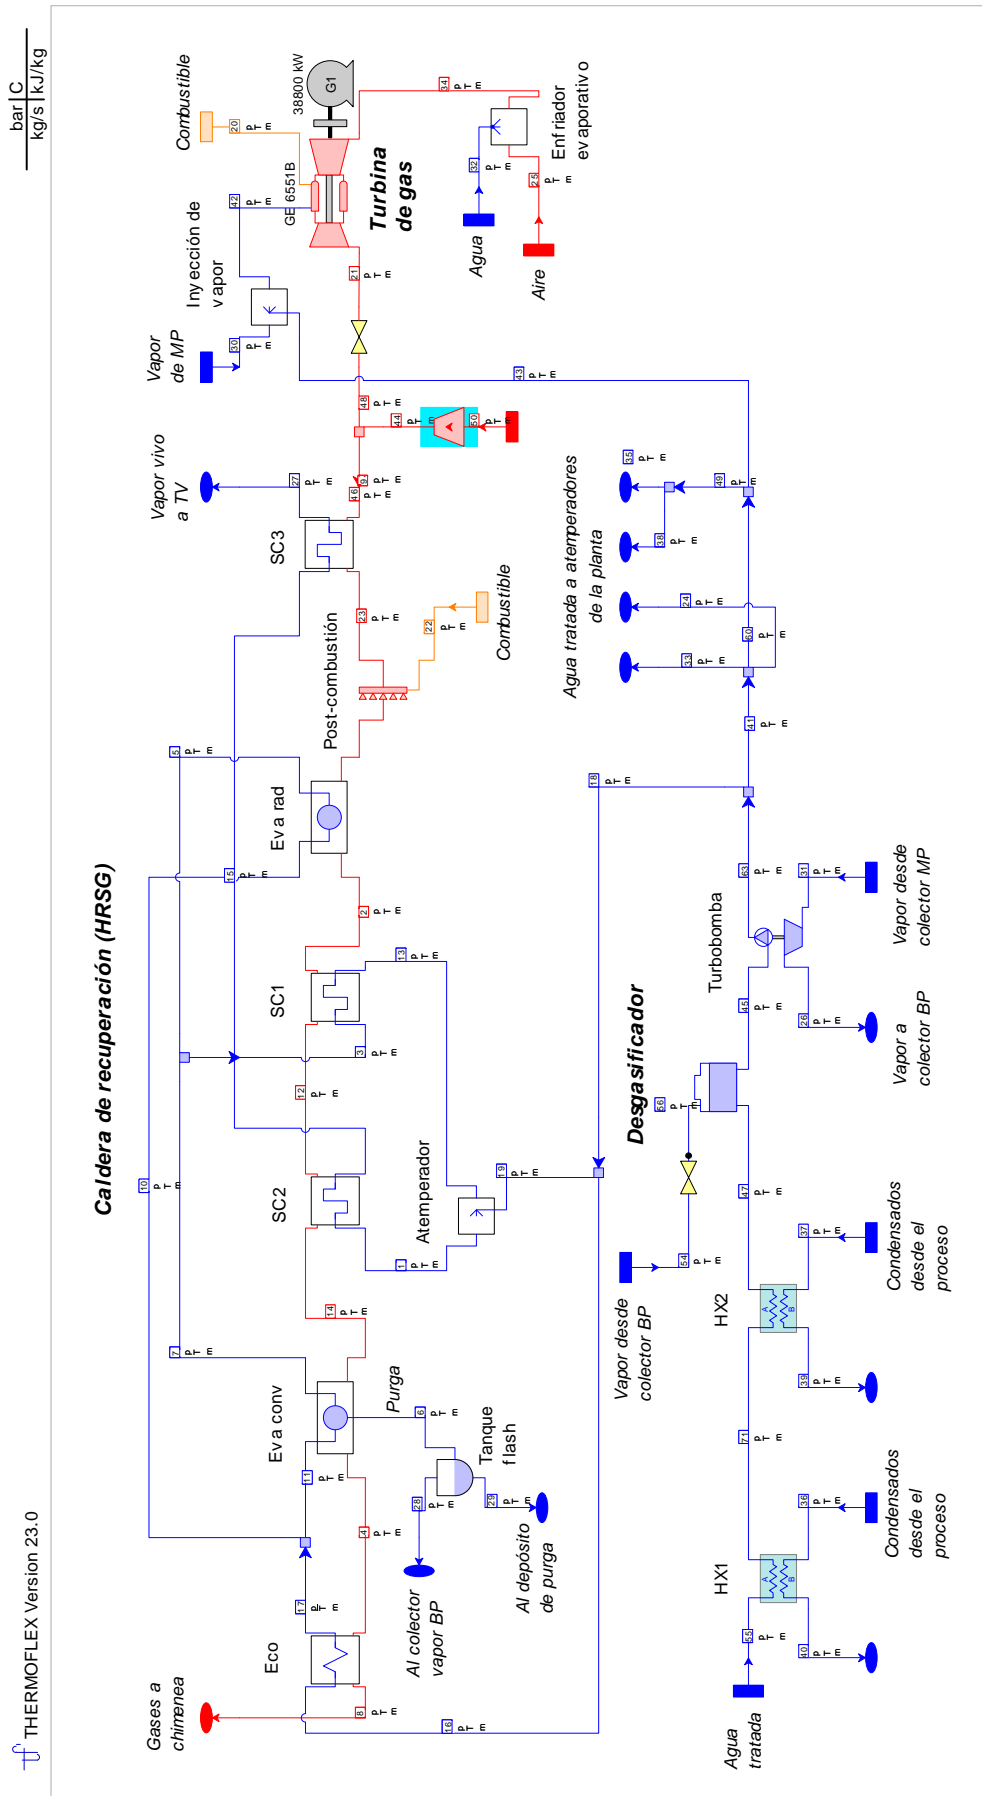


Figura 23. Esquema del modelo de simulación de la planta de cogeneración (Thermoflex 23.0).

En el esquema de [figura 23](#) pueden observarse los componentes principales de la planta:

A Turbina de gas

El modelo incluye el enfriador evaporativo del aire a la entrada del compresor y el sistema de inyección de vapor en la cámara de combustión. El simulador fue configurado para reproducir el funcionamiento de la turbina de gas tanto a carga total como a carga parcial. Atendiendo a los tipos de funcionamiento de la turbina comentados en la [fase 1](#), existen distintas formas de implementar el modo de operación a carga reducida en el simulador, en función del tipo de carga parcial que se quiere reproducir:

- Potencia fijada

En este caso el modelo de la turbina reproduce de forma fiel la acción del sistema de control real, ya que el simulador permite fijar el valor de la potencia eléctrica generada como un dato de entrada al modelo.

- Apertura fijada al mínimo de los VIGV (para limpiezas “carbo-blasting”)

Se simula la turbina fijando su porcentaje de carga, al no ser disponible la apertura de los VIGV como variable de entrada al modelo.

Con el objetivo de que la simulación reprodujera de forma correcta el funcionamiento de la turbina a carga parcial, se procedió a la configuración previa del modelo en lo referido al control de la turbina. Como parámetro de juicio de la fidelidad del modelo se utilizó el nivel de ajuste entre los resultados de simulación y los datos medidos operativos, siendo los principales parámetros a cuadrar el consumo de combustible y la temperatura de los gases de escape (la potencia generada es un valor que se fija, de forma directa o indirecta, según los dos modos de operación antes mencionados). De cara a este objetivo, se destaca la importancia de las dos variables de configuración del modelo que incluye el simulador para el ajuste, indicadas en la [figura 24](#).

Gas Turbine Main Inputs	Inlet Heating	Model Adjustments	Controls, Margins, & Genset Losses
1. TIT control model; 0=direct, 1=inferred		<input type="text" value="0"/>	
2. XIGV for direct TIT control model (single shaft GTs)		<input type="text" value="5"/>	

Figura 24. Parámetros del simulador para el ajuste del control en el modelo de la turbina de gas.

- Variable 1 – Modelo de control de la temperatura de entrada a la turbina (TET)

El usuario puede elegir entre:

- ✓ Control directo de la TET. Se habilita eligiendo el valor 0.
- ✓ Control indirecto de la TET, para obtener una temperatura de escape determinada. Se habilita eligiendo el valor 1.

Sólo en el caso de escoger la primera opción, se procede a configurar la variable 2.

- Variable 2 – VIGV para control directo de la TET

El usuario puede modificar el comportamiento de la turbina a carga parcial definiendo la magnitud relativa entre la reducción del aire de admisión (regulada por la apertura de los VIGV) y de la TET. Las opciones contempladas son:

- ✓ Variable 1: valor 0 - Variable 2: valor 0. Se regula la turbina reduciendo el caudal de combustible con caudal de aire constante a la entrada, lo cual conlleva un descenso de la TET y con ello de la temperatura de escape.
- ✓ Variable 1: valor 0 - Variable 2: valor 1. Se reduce el flujo de aire (mediante cierre parcial de los VIGV) manteniendo la temperatura de escape aproximadamente constante, lo cual implica la reducción de la TET.
- ✓ Variable 1: valor 0 - Variable 2: valores altos (máximo 10). El modelo reproduce el funcionamiento a carga parcial reduciendo la entrada de aire (cierre de los VIGV) y manteniendo la TET constante, dando como resultado un aumento de la temperatura de escape.

En la [figura 25](#) se muestran, de forma cualitativa, los perfiles de la temperatura de escape y la apertura de los VIGV de una turbina de gas operando a distintos valores de carga. En la misma figura se indican las correspondencias con los distintos modos de control que permite el simulador, pudiéndose observar el efecto de seleccionar uno u otro modo sobre la temperatura de los gases de escape.




Figura 25. Modos de regulación de la carga de una turbina de gas.

Del análisis de los registros pudo observarse que la temperatura de escape aumentaba en las horas de reducción de carga de la turbina de gas. Por esta razón se escogió un valor 0 para la variable 1 y un valor superior a 1 para la variable 2. El valor de la

variable 2 que proporcionó el mejor ajuste entre simulaciones y mediciones es 5. Haciendo referencia a la [figura 25](#), esta solución se corresponde al modo de control de carga representado por el segmento AB.

B Caldera de recuperación

Los componentes de la caldera se encuentran ubicados según la misma configuración mostrada en [figura 1](#). En concreto, empezando por el lado “frío” de la caldera, se encuentran:

- ✓ Economizador;
- ✓ Sección convectiva del evaporador (banco de convección);
- ✓ Sobrecalentador secundario;
- ✓ Sobrecalentador primario;
- ✓ Sección radiante del evaporador (hogar);
- ✓ Quemador de post-combustión;
- ✓ Sobrecalentador final.

En el modelo el hogar y el banco de convección están dispuestos como equipos en paralelo que se alimentan por el agua a la salida del economizador. Esta disposición fue adoptada de acuerdo con las posibilidades que ofrece el simulador, aunque no se corresponda con la configuración real de la caldera, ya que en realidad ambos bancos de evaporación se alimentan de la fase líquida procedente del calderín (ref. [figura 1](#)).

El modelo de simulación recoge también el aporte de aire de la soplante de sello (para el cierre estanco de las compuertas de chimenea de by-pass), que aun pequeño es significativo, por el enfriamiento que supone en los gases previamente a su entrada en el sobrecalentador final del vapor.

También en este caso el simulador permite reproducir de forma fiel la estrategia de control de la planta, a través de un lazo de control en el cual se asigna el caudal de vapor vivo generado como una variable de entrada y se mantiene el set-point fijado actuando sobre la carga del quemador de post-combustión en la caldera de recuperación.

C Desgasificador

La simulación del desgasificador es simple y fiel a la operación del sistema, ya que requiere únicamente asignar la presión de operación del mismo. En el modelo se incluye la válvula del vapor de alimentación de BP encargada del control de dicha presión.

A la salida del desgasificador, antes de la alimentación a la caldera de recuperación, se incluye la turbobomba de impulsión del agua a caldera accionada con vapor de MP, así como la bifurcación de la línea de agua de alimentación a los atemperadores de la planta.

D Intercambiadores de precalentamiento del agua de reposición

Con respecto a los intercambiadores de calor para el precalentamiento del agua tratada, destacar que su dimensionamiento fue efectuado en base a los datos operacionales. De acuerdo a la forma general de proceder comentada anteriormente, el objetivo del ajuste fue la minimización del error entre los resultados de la simulación y las mediciones, siendo los parámetros a cuadrar las temperaturas y caudales de agua tratada y condensados que atraviesan los intercambiadores.

E Suposiciones

A continuación se detallan algunas suposiciones y simplificaciones adoptadas para el modelado de la planta mediante simulador termodinámico.

Emisiones de NO_x

De acuerdo al protocolo de operación previo a la instalación de los nuevos quemadores de bajo NO_x, la inyección de vapor en la turbina de gas se controlaba de forma manual para mantener valores determinados de emisiones de NO_x en la chimenea de la caldera de recuperación. Este tipo de control no pudo reproducirse en el modelo, ya que el simulador no permite implementar el control del vapor inyectado en cámara de combustión como función de un valor objetivo de NO_x. Por estas razones, para el período post-retrofit, se utilizó un valor fijo del ratio vapor/combustible en la turbina de gas, igual al promedio de los valores registrados en el período previo al retrofit, lo cual reduce algo la precisión de las líneas base obtenidas por modelado termodinámico.

A cambio, el modelado termodinámico permitió la utilización de todo el período de mediciones previa al retrofit, sin necesidad de excluir los primeros meses de operación como se hizo necesario para el modelado RNA, ya que las emisiones de NO_x no se utilizan como entrada al modelo y por ello no se tuvieron que eliminar las horas de malfuncionamiento del medidor de NO_x.

Degradación de los componentes

Como se comenta más adelante, para completar la configuración del modelo se procedió al ajuste directo de algunos parámetros de degradación de la turbina de gas. Dichos valores dependen del número de horas de operación ocurridas entre limpiezas off-line de la turbina y del número de limpiezas efectuadas.

Para estas variables se adoptó una simplificación, que consiste en utilizar las mismas tendencias registradas en el período previo a los cambios y utilizarlas también para el período post-retrofit, tanto para los factores de degradación de la turbina de gas como para las pérdidas de carga en la línea del aire de admisión.

6.6.2 Interfaz del modelo para simulaciones masivas

En las [figuras 26 y 27](#) se muestra el interfaz del modelo que fue creado con el objetivo de realizar simulaciones masivas, aptas a reproducir el comportamiento de la cogeneración durante períodos seguidos de operación y para la posterior validación a través de la comparación con los datos medidos. Las dos tablas de las que se compone el interfaz recogen las variables de entrada con las cuales se alimenta el modelo ([figura 26](#)) y las variables de salida calculadas que cumplen con el balance de masa y energía del sistema ([figura 27](#)).

	ENTRADAS AL MODELO (Input)	Unidades	Valor	Tipo de variable (Med/Calc/Input manual)	Identificador medidor
Condiciones ambientales	Temperatura ambiente	°C	15,5	Medición	3PHD:CGTI_071.PV- VALOR (°C)
	Humedad relativa ambiente	%	54,430	Medición	3PHD:CGAI_001.PV- VALOR
	Presión atmosférica	bar	1,017	Medición	3PHD:CGPI_002.PV- VALOR (mbar)
Parámetros operativos turbina de gas	Temperatura aire salida enfriador evaporativo	°C	13,8	Medición	3PHD:CGTI_021.PV- VALOR (°C)
	Porcentaje de carga de la turbina de gas	%	100,000	Input manual	
	Caudal de vapor de inyección en turbina de gas	kg/s	1,46	Medición	3PHD:CGFI_083.PV- VALOR (t/h)
	Pérdida de carga filtros a la entrada de la turbina de gas	milibar	2,5	Medición	3PHD:CGPI_070.PV- VALOR (mm H2O g.)
Parámetros de degradación turbina de gas	Reducción del caudal de aire de admisión a la turbina de gas	%	0,121	Input manual	
	Reducción de la eficiencia del compresor de la turbina de gas	%	3,423	Input manual	
	Reducción de la eficiencia de la turbina de gas	%	0,293	Input manual	
Propiedades combustible turbina de gas	Presión de alimentación combustible a turbina de gas	bar	17,132	Medición	3PHD:CGPI_067.PV- VALOR (bar)
	Temperatura de alimentación combustible a turbina de gas	°C	25,0	Medición	3PHD:COTI_015.PV- VALOR (°C)
	Porcentaje seco de C en combustible a turbina de gas	%	20,860	Input manual	
	Porcentaje seco de H en combustible a turbina de gas	%	79,100	Input manual	
	Porcentaje seco de O en combustible a turbina de gas	%	0,000	Input manual	
	Porcentaje seco de N en combustible a turbina de gas	%	0,040	Input manual	
	Porcentaje seco de S en combustible a turbina de gas	%	0,000	Input manual	
Propiedades combustible post-combustión	Porcentaje en peso de vapor de agua en combustible turbina de gas	%	0,000	Input manual	
	Temperatura de alimentación combustible a quemador de post-combustión	°C	21,1	Medición	3PHD:COTI_016.PV- VALOR (°C)
	Porcentaje seco de C en combustible a quemador de post-combustión	%	20,860	Input manual	
	Porcentaje seco de H en combustible a quemador de post-combustión	%	79,100	Input manual	
	Porcentaje seco de O en combustible a quemador de post-combustión	%	0,000	Input manual	
	Porcentaje seco de N en combustible a quemador de post-combustión	%	0,040	Input manual	
	Porcentaje seco de S en combustible a quemador de post-combustión	%	0,000	Input manual	
Parámetros operativos caldera de recuperación	Porcentaje en peso de vapor de agua en combustible post-combustión	%	0,000	Input manual	
	Presión agua entrada economizador (Eco)	bar	91,690	Medición	3PHD:CUPI_058.PV- VALOR (kg/cm2g)
	Temperatura vapor salida atemperador previo a SC2	°C	367,1	Medición	3PHD:CUTC_003.PV- VALOR (°C)
	Purga evaporador convectivo (Eva conv)	%	1,055	Medición	3PHD:CUFI_014.PV- VALOR (t/h)
	Caudal de aire sopla de sello	kg/s	2,0	Input manual	
Parámetros operativos y de diseño desgaseificador	Presión de diseño desgaseificador	bar	3,968	Input manual	
	Temperatura vapor alimentación a desgaseificador (antes de paso por válvula)	°C	158,8	Medición	3PHD:CVTC_210.PV- VALOR (°C)
Parámetros operativos tren de precalentamiento agua tratada	Setpoint de presión a la salida válvula vapor desgaseificador	bar	3,968	Medición	3PHD:COPC_040.PV- VALOR (kg/cm2g)
	Presión agua tratada a la entrada de HX1	bar	10,000	Input manual	
	Temperatura agua tratada a la entrada de HX1	°C	15,5	Medición	3PHD:CGTI_071.PV- VALOR (°C)
	Caudal agua tratada a la entrada de HX1	kg/s	45,36	Medición	3PHD:COFI_092.PV- VALOR (t/h)
	Presión condensados a la entrada de HX1	bar	7,990	Medición	3PHD:COPC_055.PV- VALOR (kg/cm2g)
	Temperatura condensados a la entrada de HX1	°C	140,0	Cálculo	
	Caudal condensados a la entrada de HX1	kg/s	0,00	Medición	3PHD:CUFI_307.PV- VALOR (m3/h)
	Presión condensados a la entrada de HX2	bar	10,000	Input manual	
	Temperatura condensados a la entrada de HX2	°C	113,5	Medición	3PHD:CUTI_522.PV- VALOR (°C)
	Caudal condensados a la entrada de HX2	kg/s	16,86	Cálculo	
Parámetros operativos y de diseño turbobomba	Presión vapor de alimentación turbobomba	bar	19,536	Medición	3PHD:CVPI_007.PV- VALOR (kg/cm2g)
	Altura dinámica total de la turbobomba en el punto de diseño	bar	119,973	Input manual	
Lazo de control vapor vivo	Setpoint del lazo de control (caudal de vapor vivo caldera de recuperación)	kg/s	37,22	Medición	3PHD:CUFX004B.PV- VALOR (t/h)
	Variable de control del lazo de control	Caudal de combustible post-combustión		Es una salida del modelo	
				Total medidores	21

Figura 26. Interfaz del modelo termodinámico para la realización de simulaciones masivas. Entradas al modelo.

Capítulo 4. Cuantificación de ahorros. Metodología propuesta

	SALIDAS DEL MODELO (Output)* <i>* Selección de las variables de salida más destacadas para validación de resultados</i>	Units	Output	Criterio evaluación (Med/Usuario)	Identificador medidor
Propiedades combustible	Poder calorífico combustible a turbina de gas	kJ/kg	49217,4	Medición	3PHD:UCG02.281- VALOR (kcal/nm3)
	Poder calorífico combustible a quemador de post-combustión	kJ/kg	49217,4	Medición	3PHD:UCG02.281- VALOR (kcal/nm3)
Turbina de gas	Potencia eléctrica activa en bornes del alternador	kW	38317	Medición	3PHD:CEJL_064.PV- VALOR (MW)
	Heat Rate bruto turbina de gas (PCI)	kJ/kWh	11745	Usuario	
	Potencia consumida combustible turbina de gas (PCI)	kW	125005	Usuario	
	Caudal combustible turbina de gas	kg/s	2,540	Medición	3PHD:COFY_121.PV- VALOR (nm3/h)
	Temperatura gases escape turbina de gas	°C	543,3	Medición	3PHD:CGTI_019.PV- VALOR (°C)
	Caudal gases escape turbina de gas	kg/s	144,9	Usuario	
	Presión gases escape turbina de gas	bar	1,032	Medición	3PHD:CUPI_049.PV- VALOR (mm H2O g.)
Sobrecalentador final de vapor (SC3)	Presión gases tras mezcla con aire de sello	bar	1,032	Medición	3PHD:CUPI_049.PV- VALOR (mm H2O g.)
	Temperatura gases tras mezcla con aire de sello	°C	536,8	Medición	3PHD:CUTI_053.PV- VALOR (°C)
	Caudal gases tras mezcla con aire de sello	kg/s	146,9	Medición	3PHD:COB1.CAU- VALOR (nm3/d)
	Presión vapor salida sobrecalentador	bar	86,180	Medición	3PHD:CUPC_001.PV- VALOR (bar)
	Temperatura vapor salida sobrecalentador	°C	474,7	Medición	3PHD:CUTI_001.PV- VALOR
	Caudal vapor salida sobrecalentador	kg/s	37,22	Medición	3PHD:CUFX004B.PV- VALOR (t/h)
Post-combustión	Caudal de combustible post-combustión	kg/s	1,122	Medición	3PHD:COFY_283.PV- VALOR (nm3/h)
	Temperatura gases a la salida del quemador	°C	784,9	Medición	3PHD:CUTI_058.PV- VALOR (°C)
	Caudal gases a la salida del quemador	kg/s	148,1	Medición	3PHD:COB1.CAU- VALOR (nm3/d)
Evaporador - sección radiante (Eva rad)	Presión vapor a la salida del evaporador	bar	91,690	Medición	3PHD:CUPI_003.PV- VALOR (bar)
	Temperatura vapor a la salida del evaporador	°C	304,6	Medición	3PHD:CUTI_352.PV- VALOR (°C)
	Caudal vapor a la salida del evaporador	kg/s	15,96	Usuario	
	Presión gases a la salida del evaporador	bar	1,025	Medición	3PHD:CUPI_057.PV- VALOR (mm H2O g.)
	Temperatura gases a la salida del evaporador	°C	650,4	Medición	3PHD:CUTI_084.PV- VALOR (°C)
Sobrecalentador vapor SC1	Temperatura gases salida sobrecalentador	°C	577,4	Medición	3PHD:CUTI_078.PV- VALOR (°C)
	Presión vapor salida sobrecalentador	bar	89,930	Usuario	
	Temperatura vapor salida sobrecalentador	°C	387,0	Usuario	
	Caudal vapor salida sobrecalentador	kg/s	36,26	Usuario	
Atemperador vapor a la salida de sobrecalentador SC1	Presión vapor salida atemperador	bar	89,930	Usuario	
	Temperatura vapor salida atemperador	°C	367,1	Medición	3PHD:CUTC_003.PV- VALOR (°C)
	Caudal vapor salida atemperador	kg/s	37,22	Medición	3PHD:CUFX004B.PV- VALOR (t/h)
	Caudal agua alimentación atemperador	kg/s	0,955	Usuario	3PHD:CUFI_015.PV- VALOR (kg/h)
Sobrecalentador vapor SC2	Temperatura gases salida sobrecalentador	°C	539,7	Usuario	
Evaporador - sección convectiva (Eva conv)	Temperatura purga evaporador	°C	304,6	Usuario	
	Caudal purga evaporador	kg/s	0,214	Medición	3PHD:CUFI_014.PV- VALOR (t/h)
	Presión vapor a la salida del evaporador	bar	91,690	Medición	3PHD:CUPI_003.PV- VALOR (bar)
	Temperatura vapor a la salida del evaporador	°C	304,6	Medición	3PHD:CUTI_352.PV- VALOR (°C)
	Caudal vapor a la salida del evaporador	kg/s	20,30	Usuario	
	Temperatura gases a la salida del evaporador	°C	358,0	Usuario	
Economizador (Eco)	Temperatura gases salida economizador	°C	209,3	Medición	3PHD:CUTI_095.PV- VALOR (°C)
	Caudal volumétrico gases salida economizador	m3/s	207,7	Medición	3PHD:COB1.CAU- VALOR (nm3/d)
	Porcentaje molar O ₂ en gases salida economizador	%	10,91	Medición	3PHD:CUAI_096.PV- VALOR (% (V/V))
	Presión agua de alimentación caldera	bar	121,200	Medición	3PHD:CUPI_058.PV- VALOR (kg/cm2g)
	Temperatura agua de alimentación caldera	°C	145,0	Medición	3PHD:CUTI_019.PV- VALOR (°C)
	Caudal agua de alimentación caldera	kg/s	36,47	Medición	3PHD:CUFC_006.PV- VALOR (t/h)
Precalentador agua tratada (HX1)	Temperatura agua tratada salida intercambiador	°C	15,6	Medición	3PHD:CDTI_520.PV- VALOR (°C)
	Temperatura condensados salida intercambiador	°C	140,0	Medición	3PHD:COTC_054.PV- VALOR (°C)
Precalentador agua tratada (HX2)	Temperatura agua tratada salida intercambiador	°C	58,2	Medición	3PHD: CDTI_521.pv- VALOR
	Temperatura condensados salida intercambiador	°C	28,1	Medición	3PHD:CUTI_523.PV- VALOR (°C)
Desgasificador	Temperatura vapor BP alimentación desgasificador	°C	158,8	Usuario	
	Caudal vapor BP alimentación desgasificador	kg/s	5,57	Medición	3PHD:COFU_090.PV- VALOR (t/h)
	Presión agua desgasificada	bar	3,968	Medición	3PHD:COPC_040.PV- VALOR (kg/cm2g)
	Temperatura agua desgasificada	°C	143,3	Medición	3PHD:CUTI_019.PV- VALOR (°C)
	Caudal agua desgasificada	kg/s	39,12	Medición	3PHD:COFU_091.PV- VALOR (t/h)
Turbobomba	Temperatura vapor salida turbina de accionamiento	°C	172,2	Usuario	
	Caudal vapor salida turbina de accionamiento	kg/s	6,35	Usuario	
				Total medidores	33

Figura 27. Interfaz del modelo termodinámico para la realización de simulaciones masivas. Salidas seleccionadas para la validación.

A Algoritmo de simulación masiva

El interfaz está implementado en una hoja Excel, que se utilizó para vincular la base de datos horaria al modelo de simulación. El software Thermoflex permite la vinculación del modelo a la hoja Excel de interfaz y prevé un código Visual Basic que requirió de algunas modificaciones para su adecuación a las funciones del algoritmo, que son las siguientes:

- Lectura y copia de los valores de entrada al modelo desde la base de registros.
- Actualización de la tabla de entradas al modelo con los valores copiados.
- Simulación del modelo, bajo los valores de entrada actualizados.
- Copia de las salidas del modelo y actualización de la tabla correspondiente.
- Copia de los valores de ambas tablas (entradas y salidas) de la hoja Excel de interfaz y almacenamiento en otra hoja de resultados. Este paso requiere la reorganización de los valores, ya que es preferible almacenar los resultados por filas, de forma que cada fila de valores se corresponda con una hora de operación de la planta.

B Variables de entrada

Categorías de variables

Las variables de entrada al modelo, tal y como se observa de la primera de las dos tablas del interfaz, se dividen en dos categorías principales:

- Variables medidas y calculadas:
Sus valores se alimentan directamente de la base de registros previamente filtrada y acondicionada (fase 5 de la metodología), a excepción de las dos variables para las cuales no se dispone de medidores y cuyos valores pudieron calcularse a partir de otros: caudal másico de condensados a la entrada del intercambiador HX2 y temperatura de los condensados a la entrada del intercambiador HX1.
- Parámetros de ajuste introducidos manualmente:
Entre otros, se destacan los factores de degradación de la turbina de gas, que están contemplados entre los parámetros de ajuste del simulador (figura 28).

Gas Turbine Main Inputs	Inlet Heating	Model Adjustments
1. GT inlet airflow reduction		0,121 %
2. GT compressor efficiency reduction		3,423 %
3. GT turbine efficiency reduction		0,293 %

Figura 28. Parámetros de ajuste del modelo para la degradación de la turbina de gas.

Los valores de estos factores de degradación fueron obtenidos manualmente de forma empírica e iterativa, según el criterio de minimizar las diferencias entre valores simulados y registros en lo referido a las prestaciones de la turbina de gas. Se destaca el carácter altamente oneroso de esta tarea, ya que supuso el análisis y el cuadro de la evolución temporal de la degradación de la turbina para el período comprendido entre las dos paradas de la planta en las cuales se efectuaron limpiezas “offline” de la turbina (limpiezas efectuadas en los días 11 junio 2007 y 21 abril 2008).

En total, excluyendo los medidores repetidos, el modelo necesita un total de 21 medidores para la alimentación y actualización de la tabla de entradas en cada hora de operación simulada.

Notas aclaratorias

Con respecto a las variables que aparecen en la tabla de interfaz de “Entradas al modelo (Input)”, se incluyen algunas consideraciones como ayuda para la comprensión de la lógica de manejo y funcionamiento del modelo termodinámico.

1. El caudal de vapor de inyección de vapor en la turbina de gas ha tenido que utilizarse como una entrada al modelo por las limitaciones del software, que impiden la introducción de las emisiones de NO_x (de las cuales se dispone de mediciones) como entrada.
2. La composición química del combustible (gas natural) es fijada manualmente, de acuerdo al criterio de minimización del error entre el poder calorífico inferior calculado por el modelo y los valores medidos correspondientes.
3. Para el caudal de aire de la soplante de sello no se dispone de medidor, de forma que se introduce manualmente, hasta cuadrar el caudal medido de gases tras el quemador de post-combustión y el perfil de temperaturas de los gases medidas a lo largo de su paso por la caldera de recuperación.
4. El lazo de control empleado no responde exactamente a la estrategia real de control de la planta. En la realidad el caudal de combustible en la post-combustión se regula para compensar las fluctuaciones de la presión del vapor en la línea del vapor vivo. No obstante, el software no contempla el modelado dinámico del sistema, es decir, no permite reproducir los transitorios de presión del vapor sino que calcula el punto de equilibrio estacionario de la planta. De allí la necesidad de utilizar el caudal de vapor vivo como variable controlada, de forma que la presión del vapor vivo aparece entre las salidas del modelo (tabla de salidas del interfaz). El caudal de vapor vivo aparece también entre las salidas del modelo, en el sentido de que es necesario comprobar que el simulador cierre el balance de masa y energía del sistema cumpliendo con el set-point fijado en el panel de entradas al modelo, compatiblemente con el margen de error permitido en fase de definición del lazo de control (figura 29).

Define Control Loops

Define Control Objective

Total Number of Control Loop = 1

Current Control Loop No. 1

Control Loop1

☒ Current Control Loop Enabled

Type of Control

☒ Set Point Control ☐ Parameter Matching Control

Select Output Objective

Output A: Water Sink [12] : Mass flow kg/s

Output B:

Set Point Value for Output A: 37,22 kg/s

Tolerance: 0,001 As fraction, unless Set Point = 0

Buttons: Cancel, OK, Clear All Controls & Exit

Define Control Loops

Define Control Objective

Primary Control Input

Select Variable: Duct Burner - Classic [10] : Desired fuel flow kg/s

Remove Variable:

From: 0,5 To: 2,3

Calculated Value:

Upper Control Input

Select Variable:

Remove Variable:

From: To:

Calculated Value:

Lower Control Input

Select Variable:

Remove Variable:

From: To:

Calculated Value:

Figura 29. Definición del lazo de control de generación de vapor vivo en la caldera de recuperación.

C Variables de salida

Criterios de evaluación

Para las variables de salida del modelo, tal y como puede observarse de la segunda tabla del interfaz, se adoptan dos criterios de validación de los valores calculados por el modelo:

- Comprobación por medición:
Se comparan los valores calculados con los registros de los medidores correspondientes, que es la forma más directa de validación del modelo.
- Comprobación por el usuario:
Para aquellas variables que son de importancia para la validación del modelo y para las cuales no se dispone de mediciones, se generan unas salidas específicas cuyos valores han de ser validados de forma independiente por el usuario, atendiendo a criterios inspirados en el conocimiento físico del sistema.

En total, atendiendo a las variables seleccionadas y excluyendo los medidores repetidos, la comprobación de las salidas calculadas necesita un total de 33 medidores, con un total de 54 medidores requeridos para la validación del modelo termodinámico.

Notas aclaratorias

Con respecto a las variables que aparecen en la tabla de interfaz de “Salidas del modelo (Output)”, son necesarias unas aclaraciones que permitan esclarecer la lógica de utilización del simulador.

1. Los valores de Heat Rate y potencia consumida por la turbina de gas, como es lógico, no son directamente medibles y por ello se eligen entre las salidas del modelo, con el objetivo de monitorizar su evolución y asegurar que no se produzcan anomalías en el curso de las simulaciones. Por otro lado, el caudal de combustible sí es una variable de salida que puede compararse con los registros, tanto para la turbina de gas como para el caso del quemador de post-combustión.
2. Entre las salidas del modelo se han seleccionado las temperaturas y presiones de los gases a la entrada y salida de los intercambiadores de la caldera de recuperación, de forma que pudieran comprobarse los perfiles de estas propiedades a lo largo de la caldera, comparándolos con los valores medidos disponibles. Se destaca la dificultad de alcanzar cuadros completos con todos los valores medidos y, en línea general, para la comprobación se han priorizado los valores de contrapresión al escape de la turbina y de temperatura de los gases en chimenea, asignando orden de importancia secundario a la comprobación de los perfiles de temperatura y presión internos a la caldera.

3. Para el sobrecalentador final (SC3) se procede a la comprobación de los valores calculados de caudal, temperatura y presión del vapor vivo, todos valores con alta prioridad para la validación del modelo.
4. Para los caudales de vapor generados por los dos evaporadores no se dispone de mediciones separadas, de forma que el usuario revisa los valores calculados de forma independiente, siempre con la comprobación de que se cumpla el caudal total de vapor fijado por el set-point del lazo de control de vapor vivo.
5. Para el lado agua/vapor, se comprueban los valores calculados de caudal, temperatura y presión de la corriente agua/vapor en su paso por el tren de precalentamiento de agua tratada y por los intercambiadores de la caldera de recuperación comparándolos con los registros, en todos los casos en los que se dispone de medidores. Para los demás casos se aplica la misma forma de proceder, seleccionando aquellas variables de salida del modelo que permitan monitorizar los perfiles de estas propiedades a lo largo de la caldera aunque no puedan compararse directamente con valores medidos.
6. Con respecto al desgasificador, especial relevancia cobra la comprobación del consumo de vapor de BP, al ser uno de los parámetros afectados por las MAE y para el cual se quiere generar la línea base.

6.6.3 Validación del modelo

Una vez efectuado el dimensionamiento de los principales equipos del sistema (básicamente se trata del diseño de los intercambiadores de la caldera y de los precalentadores de agua tratada), se simuló la planta en condiciones fuera de diseño y se compararon los resultados con los datos medidos. Como se ha comentado en las secciones anteriores, los ajustes del modelo se realizaron de forma manual, con el objetivo de minimizar los errores entre registros y salidas del modelo.

A Simulaciones masivas en períodos representativos de la operación

Para la operación a carga total de la turbina de gas se efectuaron simulaciones masivas de la planta sobre breves períodos continuados, para validar la capacidad del modelo para simular días seguidos de operación.

La selección de los períodos de validación fue efectuada atendiendo a criterios de variabilidad y riqueza de información en los datos, de forma que fueran cubiertos escenarios diversos de operación de acuerdo a los principales parámetros operativos, tanto incontrolados (fluctuaciones de la electricidad producida por la turbina de gas, que depende fuertemente de la temperatura exterior) como regulados (inyección de vapor en la turbina de gas, combustible quemado en la post-combustion, presión en el desgasificador).

Para validar el modelo a carga total de simularon un total de 858 horas de operación. Para la operación a carga parcial se emplearon todos los datos disponibles, debido a su número mucho más exiguo: 280 simulaciones en total.

B Capacidad de predicción del modelo termodinámico

La [figura 30](#) muestra los resultados de validación para la generación de electricidad de la turbina de gas operando a carga total.

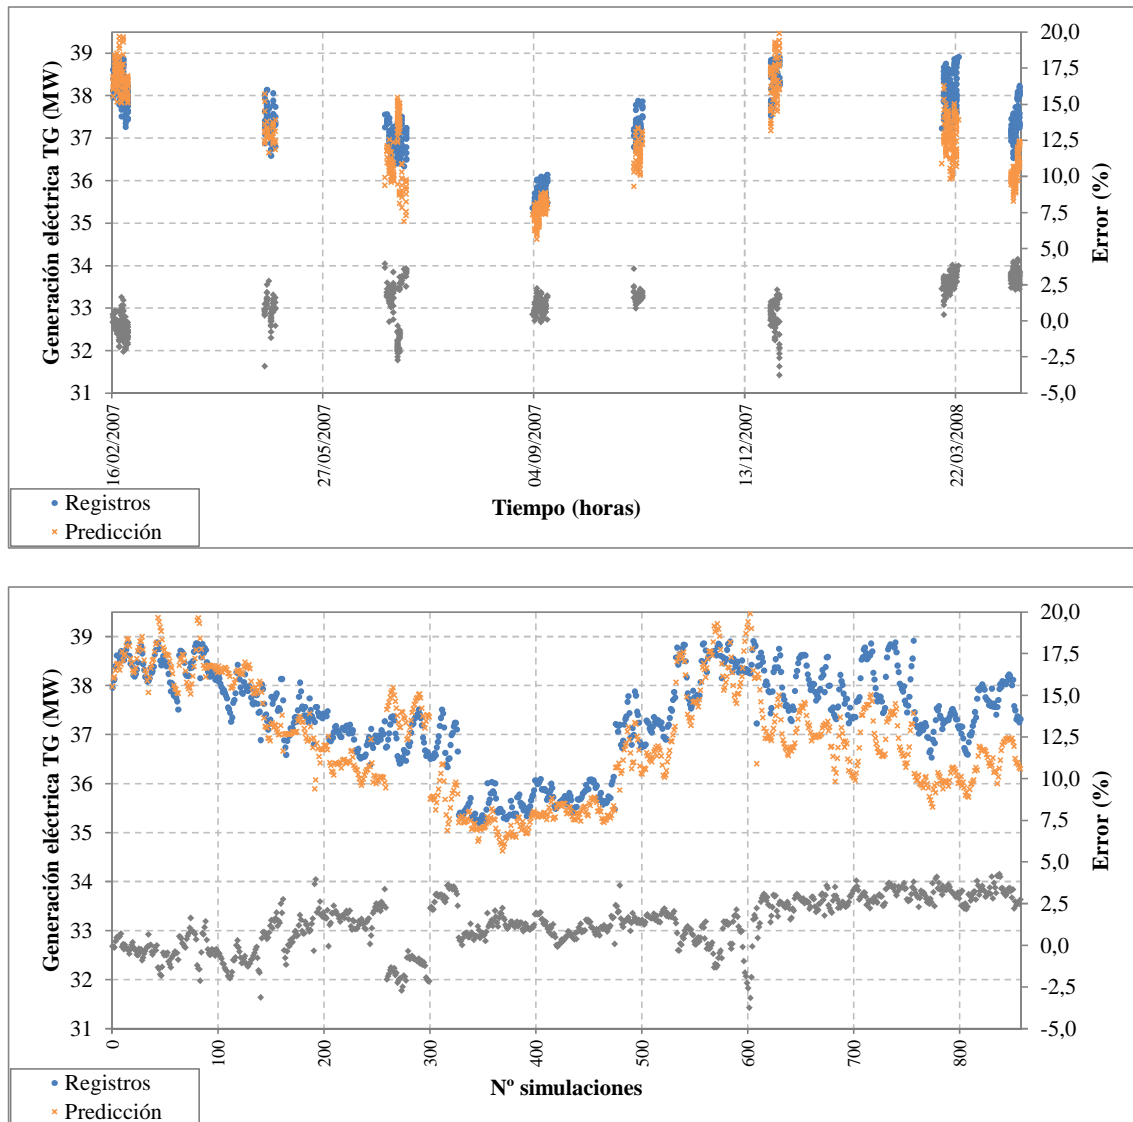


Figura 30. Resultados de validación del modelo termodinámico para la electricidad generada en turbina de gas a carga total. Selección de los períodos de operación (arriba) y unificación de los mismos (abajo).

Los datos se presentan ordenados por fecha, de modo que se puede observar la selección realizada, junto con la fuerte influencia de la temperatura ambiente sobre el perfil de evolución de la generación eléctrica de la turbina. Para mayor claridad, los períodos simulados fueron unificados y el resultado se muestra en el segundo diagrama.

Los niveles de error obtenidos son satisfactorios, aunque más altos que los del modelo RNA correspondiente. Sólo el 40% de los puntos presenta errores inferiores al 1,0%, frente al 89% de las predicciones RNA que cumplen la misma condición. Aun así, la capacidad de predicción del modelo puede considerarse aceptable, ya que el 65% de los errores calculados son inferiores al 2,0% y el restante 35% tiene valores inferiores a 5,0%. No se detecta comportamiento sistemático del error y se observa la misma tendencia aleatoria como para los modelos RNA.

En las [figuras 31-34](#) se muestran algunos de los resultados más significativos obtenidos en fase de validación del modelo termodinámico de la cogeneración.




Figura 31. Resultados de validación del modelo termodinámico para el consumo de combustible en turbina de gas.




Figura 32. Resultados de validación del modelo termodinámico para el consumo de vapor en el desgasificador.




Figura 33. Resultados de validación del modelo termodinámico para el consumo de combustible en post-combustión.




Figura 34. Resultados de validación del modelo termodinámico para la producción de vapor vivo.

Entre los resultados no se incluye el consumo de vapor de inyección en turbina de gas, debido a las simplificaciones (comentadas anteriormente) que han sido adoptadas para el modelado de dicho parámetro.

Se observan niveles aceptables de error para el consumo de combustible en turbina de gas y en el quemador de post-combustión (figuras 31, 33), aunque en el segundo caso el error aumenta significativamente en el segundo tramo del período de verificación presentando un carácter sistemático. Esta tendencia se debe principalmente a la reducción de precisión del modelo a la hora de reproducir el comportamiento de la planta a carga reducida: en la figura 34 se puede observar como la generación de vapor vivo en la caldera de recuperación se reduce en el período en consideración. Nótese también la coincidencia entre los registros y las predicciones en figura 34, debida al lazo de control del vapor vivo en caldera implementado en el simulador. En

la [figura 33](#) no se representan los datos reales de operación en el primer tramo del período de validación, ya que en ese tramo se dieron fallos en el medidor de combustible.

Se destaca que las divergencias más significativas entre datos simulados y registros se dan para el consumo de vapor de BP en el desgasificador ([figura 32](#)). Eso se debe a la propagación de los errores que afectan al caudal de agua tratada, mostrados en [figura 35](#). Dichos errores, relevantes y continuados sobre todo el período de validación, se justifican por la fiabilidad del medidor de agua de alimentación al desgasificador que, según información del personal de planta, registra valores por exceso.




Figura 35. Resultados de validación del modelo termodinámico para el caudal de agua tratada.

El hecho de que el caudal de agua tratada esté medido por exceso provoca un cálculo en exceso del caudal de condensados a la entrada del intercambiador HX2. Esto determina valores simulados por exceso de la temperatura del agua tratada a la entrada al desgasificador, y con ello errores por defecto en el consumo de vapor del desgasificador.

En línea general, se puede concluir que los resultados confirman la más que probada capacidad del simulador termodinámico para predecir el comportamiento de este tipo de plantas, aunque con algo menos de precisión que las RNA cuando se trata de reproducir conjuntos de datos de operación medidos. Esto puede atribuirse principalmente a la alta sensibilidad de los modelos termodinámicos a la calidad de los datos de entrada. En este sentido, la aplicación de la técnica de reconciliación de datos ayudaría a corregir los errores de medición, lo que reduciría sus repercusiones adversas sobre el modelo. Para este propósito, Thermoflow concibió un software específico para la reconciliación de datos, cuya aplicación seguramente contribuiría a mejorar la capacidad de predicción del modelo.

7. Fase 7. Determinación de los ahorros

El cálculo de los ahorros procedentes de la implantación de las MAE se articula en los siguientes pasos:

7.1 Preparación de los datos

En el período de verificación de ahorros no se dispone de registros para la validación las predicciones, ya que la función de los modelos desarrollados es justamente la de determinar las diferencias existentes con los datos medidos. Por esta razón, la única garantía de fiabilidad de las líneas base obtenidas es que las fluctuaciones registradas en las variables de entrada estén comprendidas en los mismos rangos que el período de referencia. Atendiendo a estas consideraciones, para cada uno de los modelos entrenados, previamente a la generación de las líneas base en el período de verificación de ahorros, se procede a realizar un filtrado que incluye:

1. Variables de entrada a los modelos:

Se eliminan los valores que exceden los límites máximos y mínimos alcanzados en el período de entrenamiento y validación de los modelos.

2. Variables modeladas:

- a. Se filtran los valores anómalos que corresponden a fallos en los sensores, errores en el sistema de adquisición de datos y datos vacíos.
- b. Se eliminan aquellos valores que no se corresponden al modo de operación para el cual se realizó el modelado del parámetro en cuestión. Cabe destacar que esta operación no consiste en el mismo filtrado del tipo por bandas como el que se aplica a las variables de entrada, ya que los valores del parámetro modelado, compatiblemente con el modo de operación considerado, no necesariamente deben mantenerse en los mismos rangos del período de validación de los modelos.

Una vez efectuados los filtrados, el número total de registros útiles para la verificación de ahorros se obtiene de la intersección de los registros válidos que han pasado los procesos de filtrado anteriores debido a que, para cada hora de operación de la planta, se necesitan las cinco líneas base simultáneamente para poder proceder a la verificación de los ahorros. Por esta razón, resulta indiferente el criterio con el cual se realicen los filtrados, siendo equivalente efectuarlos de forma independiente para cada modelo o de forma conjunta sobre el conjunto total de las variables de entrada y modeladas.

Para la planta de cogeneración se han realizado las operaciones de filtrado de forma conjunta para los modelos de generación eléctrica y consumo en la turbina de gas y el consumo de la post-combustión, siendo el cuerpo principal de las variables de entrada el mismo para estos tres modelos. Para la inyección de vapor en turbina y el consumo

de vapor en el desgasificador se ha procedido a un filtrado independiente, con el único objetivo de poder comprobar el correcto comportamiento de los modelos antes de la eliminación de datos que serían válidos para dichos modelos y que, sin embargo, han de ser eliminados en los modelos anteriores. Aun así, las predicciones obtenidas para estos modelos que se corresponden con las horas filtradas en los demás modelos han tenido que ser eliminadas en fase de cálculo de ahorros.

Atendiendo a los parámetros modelados y las correspondientes variables de entrada resumidas en la [tabla 5](#), a continuación se indican los resultados obtenidos de los filtrados efectuados para la planta de cogeneración.

1. La base de datos inicial se constituye de 4.090 registros, correspondientes a las horas comprendidas entre el 17/11/2008 0:00^h y el 06/05/2009 9:00^h (período de verificación de ahorros).
2. Filtrado de valores anómalos del poder calorífico inferior del combustible.

Se eliminan 166 registros, correspondientes al 4,1% de la base de datos inicial.

En la [figura 36](#) se muestra el filtrado efectuado, tras el cual la muestra queda reducida a 3.924 registros.




Figura 36. Filtrado de datos previo a la generación de las líneas base. Poder calorífico inferior del combustible.

3. Filtrado de valores anómalos del caudal de gas natural y de la potencia consumida en la turbina de gas.

Se eliminan 117 registros, correspondientes al 2,9% de la base de datos inicial.

En la [figura 37](#) se muestra el filtrado efectuado, tras el cual la muestra queda reducida a 3.807 registros.




Figura 37. Filtrado de datos previo a la generación de las líneas base. Potencia consumida en la turbina de gas.

La mayoría de las anomalías se concentran en la primera parte del período (tramos en los que el medidor devuelve valores nulos, que no pueden apreciarse debido a la escala utilizada en las gráficas), quedando por lo tanto la muestra empobrecida en esa parte.

4. Filtrado de los registros correspondientes a operación a carga parcial de la turbina de gas.

Se eliminan 416 registros, correspondientes al 10,2% de la base de datos inicial.

En la [figura 38](#) se muestra el filtrado efectuado, tras el cual la muestra queda reducida a 3.391 registros.




Figura 38. Filtrado de datos previo a la generación de las líneas base. Registros correspondientes a carga parcial de la turbina de gas.

Cabe destacar la cantidad ingente de datos eliminados en esta fase (también esta vez los efectos del filtrado se concentran en la primera parte del período), lo cual refleja una de las principales debilidades de la metodología propuesta, que es la inaplicabilidad de los modelos fuera de los modos de operación para los cuales fueron entrenados, y por ello la necesidad de cautelarse de dicha inhabilidad en esta fase de filtrado.

5. Filtrado de los valores anómalos del consumo de combustible en el quemador de post-combustión.

Se eliminan 31 registros, correspondientes al 0,8% de la base de datos inicial. En la [figura 39](#) se muestra el filtrado efectuado, tras el cual la muestra queda reducida a 3.360 registros (82,2% del conjunto de registros inicial).




Figura 39. Filtrado de datos previo a la generación de las líneas base. Consumo de combustible en la post-combustión.

7.2 Determinación de las líneas base

Se alimentan los modelos obtenidos con los valores de las entradas medidos en el período posterior a las modificaciones. De esta manera se generan los perfiles de consumo y producción de energía durante el período de verificación, para su comparación con los consumos y generaciones reales medidos en el mismo período.

Las líneas base obtenidas para la planta de cogeneración se muestran en la sección de resultados (capítulo 5).

7.3 Verificación de ahorros

Los ahorros de energía pueden determinarse mediante la integración de las diferencias entre el funcionamiento de la planta (valores medidos) y la línea base (valores

predichos por los modelos) sobre el período de verificación de ahorros. Posteriormente se calculan los beneficios económicos asociados a dichos ahorros aplicando los precios de la energía correspondientes.

Para los resultados energéticos y económicos obtenidos en la planta de cogeneración hágase referencia a la sección de resultados (capítulo 5).

***Capítulo 5.* Resultados y discusión**

En esta sección se presentan los resultados obtenidos de la aplicación de las fases 7.2 y 7.3 de la metodología propuesta a la planta de cogeneración.

1. Líneas base de la planta

1.1 Líneas base de consumo y generación

En las figuras 40-44 se muestran las líneas base obtenidas para los parámetros de consumo y generación de la cogeneración que se vieron afectados por la implantación de las MAE. En los diagramas se representan simultáneamente los valores predichos y los registros, para el período posterior a las modificaciones seleccionado para la verificación de los ahorros.




Figura 40. Generación eléctrica en turbina de gas. Valores medidos y predichos (línea base) en el período de verificación de ahorros.




Figura 41. Consumo de combustible en turbina de gas. Valores medidos y predichos (línea base) en el período de verificación de ahorros.




Figura 42. Inyección de vapor en turbina de gas. Valores medidos y predichos (línea base) en el período de verificación de ahorros.




Figura 43. Consumo de combustible en post-combustión. Valores medidos y predichos (línea base) en el período de verificación de ahorros.




Figura 44. Consumo de vapor en el degasificador. Valores medidos y predichos (línea base) en el período de verificación de ahorros.

Cabe recordar que las prestaciones de los modelos RNA han sido verificadas en la [fase 6.5](#) y su poder predictivo ha sido validado mediante la comparación de las predicciones con los datos medidos en el período previo a la modificación. Como ya se ha observado anteriormente, en esta fase del estudio ya no existe evidencia directa de la fiabilidad de las líneas base generadas, debido a que se está comparando el comportamiento del sistema bajo dos configuraciones distintas, antes y después de las modificaciones. No obstante, es necesaria la comprobación del correcto comportamiento de las líneas base obtenidas, de acuerdo a los efectos esperados de las MAE sobre las salidas de los modelos, previamente determinados en las [fases 2](#) y [3.2](#) del estudio. De acuerdo a esta forma de proceder, se observa que las líneas base evolucionan según lo esperado, ya que los datos medidos son inferiores a los valores

predichos para la generación eléctrica y el consumo de combustible en la turbina de gas (figuras 40 y 41). Para el consumo de combustible en post-combustión (figura 43) la tendencia observada es la contraria, debido a que la potencia térmica quemada en la caldera de recuperación aumenta por efecto de las MAE. Asimismo se observa el cese de inyección de vapor en la turbina de gas, siendo los valores modelados la representación del consumo de vapor de MP que se produciría en el caso de no haberse implantado las MAE en la planta (figura 42). También para el caso del consumo de vapor de BP en el desgasificador (figura 44) la línea base refleja el comportamiento esperado de la planta, ya que dicho consumo disminuyó después de la implantación del nuevo intercambiador HX3 como consecuencia de la mayor temperatura del agua precalentada a la entrada del desgasificador. Como excepción a esta tendencia, se observan casos en los que los consumos predichos y medidos presentan valores cercanos o incluso coincidentes, que se corresponden con las horas de operación en las cuales el caudal de agua tratada es desviado a la línea de bypass del precalentador.

Con respecto a la generación eléctrica de la turbina de gas (figura 40), aunque la tendencia observada sea la correcta (la potencia predicha por el modelo RNA es, en general, superior a las mediciones) se precisan algunas explicaciones que permitan esclarecer el comportamiento del modelo en la primera mitad del período de verificación, en el cual la diferencia entre mediciones y línea base es mucho menos marcada. Dicho comportamiento se debe principalmente al perfil de temperatura ambiente en el período en cuestión, caracterizado por fluctuaciones muy acentuadas en el tramo noviembre-enero si comparado, por ejemplo, con el perfil del año anterior (2008) en el mismo período, mucho más homogéneo y representativo de la climatología del lugar de emplazamiento (figura 45).




Figura 45. Perfil de temperatura ambiente en el período de verificación de ahorros (2009) y comparación con el mismo período en el año anterior (2008).




Figura 46. Temperatura ambiente y sus repercusiones sobre los valores predichos de generación eléctrica en turbina de gas en el período de verificación de ahorros.

Las fluctuaciones de la temperatura ambiente explican las bajadas de potencia eléctrica generada por la turbina de gas, tanto de las medidas como de la línea base (figura 46), que se producen en correspondencia de las excursiones hacia valores altos de temperatura. En estas ocasiones, las penalizaciones de potencia por alta temperatura disminuyen drásticamente los efectos de las MAE, reduciéndose la diferencia entre los dos perfiles de electricidad registrados y modelados. Siempre con respecto al diagrama de figura 40, se puede afirmar que el modelo RNA ha captado correctamente el modo de operación de la turbina a carga limitada, ya que la potencia predicha no supera los 39-40 MW, que es la limitación de potencia existente en los períodos invernales que garantiza que la potencia eléctrica total del sistema (turbina de gas y turbina de vapor) no sobrepase los 50 MW.

Consideraciones análogas a las anteriores se aplican al consumo de combustible en la turbina de gas (figura 41), cuya tendencia es mucho más clara en la segunda mitad del período de verificación.

La tabla 9 resume las generaciones y consumos de energía medidos y modelados. Los valores indicados se refieren a un año de funcionamiento y han sido extrapolados a partir de los resultados obtenidos (correspondientes a un semestre aproximadamente) considerando 8.400 horas anuales de funcionamiento de la planta.

PRODUCCIONES Y CONSUMOS DE ENERGÍA DE LA COGENERACIÓN				
	REAL		LÍNEA BASE	
ELECTRICIDAD				
Generación eléctrica TG	301.866	MWh/año	318.957	MWh/año
Generación eléctrica TV	95.920	MWh/año	95.920	MWh/año
Generación eléctrica total	397.786	MWh/año	414.877	MWh/año
COMBUSTIBLE				
Consumo combustible TG	999.507	MWh _{PCI} /año	1.033.139	MWh _{PCI} /año
Consumo cble post-combustión	499.440	MWh _{PCI} /año	481.760	MWh _{PCI} /año
Consumo combustible total	1.498.947	MWh _{PCI} /año	1.514.899	MWh _{PCI} /año
VAPOR				
Exportación vapor MP	825.789	t/año	781.950	t/año
Exportación vapor BP	297.424	t/año	201.826	t/año

Tabla 9. Producciones y consumos energéticos anuales de la cogeneración. Valores medidos (reales) y predichos (línea base)

1.2 Líneas base de otros parámetros de interés

Tras haber modelado los parámetros energéticos afectados por las MAE, es también necesario tener en cuenta los posibles efectos de dichas MAE sobre los factores económicos involucrados en la rentabilidad operativa de la planta. El análisis de estos cambios es esencial antes de proceder a la siguiente fase de verificación de ahorros, como muestra el caso indicado a continuación.

De acuerdo a la legislación en vigor durante el período de verificación, el incentivo concedido sobre el precio final de exportación a la red de la electricidad generada estaba vinculado al valor de eficiencia alcanzado por la planta de cogeneración, calculado en forma de un indicador específico de eficiencia denominado rendimiento eléctrico equivalente (REE), expresado por la fórmula:

$$REE = \frac{E_{CHP}}{F_{CHP} - \frac{H_{CHP}}{\eta_{ref}}} \quad (18)$$

siendo

- E_{CHP} = generación eléctrica de la cogeneración;
- F_{CHP} = consumo de combustible de la cogeneración;
- H_{CHP} = calor útil generado por la cogeneración.

El término H_{CHP}/η_{ref} representa el combustible que sería consumido en un sistema de generación de calor convencional para producir la misma cantidad de calor útil H_{CHP} y η_{ref} representa el rendimiento de este sistema convencional de referencia.

En la planta de cogeneración, H_{CHP} es el contenido entálpico liberado por el vapor entregado al proceso y η_{ref} se ha fijado en 0.9, un valor razonable para el rendimiento de referencia en generadores convencionales de vapor. La [figura 47](#) muestra la línea base del REE de la planta, obtenida por combinación de las líneas base previamente generadas.




Figura 47. Rendimiento eléctrico equivalente de la cogeneración (real y línea base).

El aumento del REE tras la implantación de las MAE se debe principalmente al aumento de las exportaciones de vapor de MP y BP, tal y como reflejan los valores indicados en la [tabla 9](#).

1.3 Comparación con el modelo de simulación termodinámica

En las [figuras 48-52](#) se muestran las líneas base predichas por ambos métodos de modelado, RNA y simulación termodinámica, junto con las diferencias porcentuales entre los valores obtenidos.

Los resultados para la generación eléctrica de la turbina de gas y los consumos de combustible en turbina de gas y post-combustión ([figuras 48, 49, 51](#)) indican diferencias relativamente pequeñas entre las líneas base generadas, del orden de 3 a 5%. Las predicciones obtenidas mediante RNA para estos tres parámetros muestran una tendencia a exceder la línea base termodinámica en la segunda parte del período observado. Una fuente de incertidumbre a la cual podrían deberse las diferencias son las suposiciones simplificadoras adoptadas para reproducir el envejecimiento de la turbina de gas en el modelado termodinámico. Por un lado, se han utilizado los parámetros de envejecimiento como variables de entrada de ajuste para incrementar la precisión de reproducción de los datos medidos en fase de validación del modelo termodinámico sobre el período anterior al retrofit. En cambio, esos parámetros generan un entorno de error en el período posterior al retrofit; de hecho, como comentado anteriormente, se han reproducido las mismas tendencias de degradación que para el período anterior al retrofit, sin que existan garantías de que eso se corresponde a la operación real de la cogeneración.

Otra posible causa de las divergencias podría estar asociada con la temperatura de alimentación del combustible, no contemplada en el modelo RNA. Después de la implantación de las MAE, se introdujo el precalentamiento del combustible como una práctica común en la operación de la planta, que resultó en una ligera reducción del

consumo de combustible y de la producción de electricidad de la turbina. No ha sido posible incluir la temperatura del combustible entre las variables de entrada a los modelos RNA debido a que, en el período anterior al retrofit, el combustible se suministraba a la turbina a temperatura ambiente y las ligeras fluctuaciones registradas no son suficientes para captar sus efectos sobre la operación de la turbina.

Las diferencias entre los resultados de los modelos son mucho más relevantes para el vapor inyectado en la turbina de gas (figura 50), siendo las divergencias de hasta el 30-35%. En este caso se puede afirmar con certeza que los resultados más fiables son los de los modelos RNA. Como comentado anteriormente, las discrepancias se asocian principalmente a las limitaciones del modelo termodinámico a la hora de reproducir el sistema de control real de la planta para la reducción de las emisiones de NO_x .

Las diferencias son también relevantes por lo que concierne a los efectos de la segunda MAE (precalentamiento de agua de alimentación al desgasificador): el consumo de vapor en el desgasificador predicho por el simulador termodinámico es significativamente inferior (figura 52) y eso es imputable, como ya observado, a los errores de medición del caudal de agua tratada, que terminan propagándose a la simulación de la línea de precalentamiento del agua. De hecho las diferencias son más reducidas en las horas de operación en las cuales la MAE implantada no está activa, es decir, en los períodos en los que el nuevo intercambiador está fuera de servicio y el consumo de vapor de BP es mayor.

Una vez más, los resultados mostrados reflejan una de las problemáticas principales asociadas con la evaluación de la línea base energética, que es el entorno de incertidumbre y la ausencia de datos de comparación que caracterizan el período posterior a las modificaciones. Limitar esta incertidumbre era de hecho uno de los objetivos de este estudio, dirigido a la aplicación de técnicas de modelado avanzadas y fiables para la determinación de perfiles energéticos de referencia creíbles.




Figura 48. Generación eléctrica en turbina de gas. Líneas base obtenidas con RNA y con modelo termodinámico.




Figura 49. Consumo de combustible en turbina de gas. Líneas base obtenidas con RNA y con modelo termodinámico.




Figura 50. Inyección de vapor en turbina de gas. Líneas base obtenidas con RNA y con modelo termodinámico.




Figura 51. Consumo de combustible en post-combustión. Líneas base obtenidas con RNA y con modelo termodinámico.




Figura 52. Consumo de vapor en el degasificador. Líneas base obtenidas con RNA y con modelo termodinámico.

3. Verificación de ahorros

Se procede al cálculo de los ahorros en el período de verificación, como diferencia entre los beneficios económicos de explotación de la planta en su configuración posterior y anterior a las modificaciones.

$$Ahorros = Beneficio_{post} - Beneficio_{pre} \quad (19)$$

pudiéndose determinar el beneficio como

$$Beneficio = Ingresos - Costes \quad (20)$$

siendo

$$Ingresos = (E \cdot pv_E) + (V_{MP} \cdot pv_{MP}) + (V_{BP} \cdot pv_{BP}) \quad (21)$$

y

$$Costes = (C \cdot pc_C) + [(V_{MP} + V_{BP}) \cdot pc_{at}] \quad (22)$$

siendo

- E = electricidad generada por la cogeneración (turbina de gas y turbina de vapor);
- pv_E = precio de venta de la electricidad exportada;
- V_{MP} = vapor de media presión exportado al proceso;
- pv_{MP} = precio de venta del vapor de media presión;
- V_{BP} = vapor de baja presión exportado al proceso;
- pv_{BP} = precio de venta del vapor de baja presión;
- C = combustible quemado por la cogeneración (turbina de gas y post-combustión);
- pc_C = precio de compra del combustible;
- pc_{at} = precio de compra del agua tratada alimentada al desgasificador.

Obsérvese que el precio de compra del agua tratada se aplica a la totalidad del vapor generado de MP y BP ya que, debido a los límites de batería establecidos para la cogeneración, el proceso no devuelve condensados a la planta y por ello ha de reponerse continuamente en el sistema una cantidad de agua tratada igual a la suma de los caudales de vapor exportado de MP y BP.

El cálculo de los beneficios y ahorros se realiza en base horaria, utilizando los valores medidos y predichos de E , C , V_{MP} y V_{BP} .

En [figura 53](#) se muestran los precios de la energía utilizados para el cálculo, obtenidos de las facturas energéticas y del contrato de venta de vapor a la refinería. Se puede observar el aumento del precio de exportación de la electricidad tras las modificaciones, debido a los mayores valores calculados para el incentivo concedido sobre ese precio, que está directamente relacionado con el REE de la planta.




Figura 53. Precios de la energía utilizados para el cálculo de beneficios y ahorros.

Los diagramas de las figuras 54-57 muestran los ingresos y costes calculados en base horaria, representándose simultáneamente los valores correspondientes a la operación real de la planta y las predicciones (línea base), junto con la diferencia entre dichos valores. Análogamente, en figura 58 se muestran los ahorros globales asociados a la implantación de las MAE en la planta de cogeneración, obtenidos como diferencia entre los ingresos y costes de las figuras 54-57.




Figura 54. Ingresos por exportación de electricidad: real, línea base y diferencia.




Figura 55. Coste del combustible: real, línea base y diferencia.




Figura 56. Ingresos por exportación de vapor de media presión: real, línea base y diferencia.




Figura 57. Ingresos por exportación de vapor de baja presión: real, línea base y diferencia.




Figura 58. Beneficio económico de explotación: real, línea base y diferencia (ahorros).

Los resultados están resumidos en la [tabla 10](#), que contiene los valores económicos anuales obtenidos de la integración de los diagramas de las [figuras 54-58](#) y posterior extrapolación a 8.400 horas de funcionamiento.

BENEFICIO ECONÓMICO DE EXPLOTACIÓN DE LA COGENERACIÓN Y AHORROS OBTENIDOS						
	REAL		LÍNEA BASE		Diferencia REAL - LÍNEA BASE	
INGRESOS						
Exportación de electricidad	29.219.953	€/año	27.895.807	€/año	1.324.146	€/año
Exportación de vapor de media presión	17.808.130	€/año	16.879.557	€/año	928.573	€/año
Exportación de vapor de baja presión	6.085.992	€/año	4137.019	€/año	1.948.973	€/año
COSTES						
Combustible	43.260.295	€/año	43.333.126	€/año	-72.832	€/año
					Ahorros	
BENEFICIO DE EXPLOTACIÓN	9.853.780	€/año	5.579.256	€/año	4.274.524	€/año

Tabla 10. Beneficio económico anual de la cogeneración (real y línea base). Ahorros obtenidos con las MAE.

Como puede observarse del diagrama en [figura 58](#), existen períodos caracterizados por valores negativos de la línea base del beneficio. La razón principal de esto reside en la tendencia de los precios de la energía y, en este sentido, el parámetro más influyente es la relación de los precios electricidad-combustible. La [figura 59](#) muestra la tendencia de esta relación a lo largo del período considerado, y se destaca la fuerte correspondencia existente con el perfil del beneficio representado en [figura 58](#).




Figura 59. Tendencia de la relación de precios electricidad-combustible.

Este aspecto merece mucha atención, ya que los modelos generados están prediciendo una operación de la cogeneración que conlleva asociada una pérdida económica. Por una parte, la diferencia constantemente existente entre el beneficio real y el predicho (figura 58) puede considerarse una especie de confirmación de que el comportamiento de la línea de base generada es el correcto. De esta forma, las predicciones de beneficios negativos pueden ser explicadas como una directa consecuencia de las disminuciones en el beneficio real que corresponden al período febrero-marzo 2009. Por otro lado, un sistema de gestión avanzado de la unidad que utilice previsiones atendibles de los precios futuros de la energía podría ser de ayuda para evitar que se produzcan períodos operativos con beneficios negativos a través de la parada de la cogeneración. Independientemente de las consideraciones asociadas a la viabilidad técnica de paradas y arranques de la planta basados en previsiones, el aspecto comentado pone de manifiesto una debilidad de la metodología de modelado propuesta, que se centra principalmente en reproducir del comportamiento energético del sistema, sin contemplar los posibles cambios en la operación de la planta dictados por cambios en los precios de la energía.

***Capítulo 6.* Conclusiones**

1. Aportaciones y aplicabilidad de la metodología propuesta

El objetivo de este trabajo ha sido abordar la problemática de la verificación de los ahorros en la industria y proporcionar una respuesta concreta más allá de las directrices generales contenidas en el IPMVP [5], en el cual no se identifican claramente las técnicas más adecuadas para la determinación de la línea de base de consumo energético en el sector industrial.

De acuerdo a este objetivo, se ha desarrollado una metodología para la cuantificación rigurosa de los ahorros asociados a la implantación de mejoras energéticas. La técnica de modelado propuesta para la determinación de la línea base de consumo/producción es la de las RNA y su idoneidad para la reproducción del comportamiento de los complejos procesos industriales resulta comprobada por el nivel satisfactorio de precisión de los modelos generados, obtenidos para la planta de cogeneración a la cual se aplica la metodología propuesta.

Al tratarse de un enfoque novedoso en el campo de la cuantificación de ahorros, se ha considerado oportuno corroborar la capacidad de predicción de los modelos estadísticos (RNA), contrastando las previsiones con la precisión obtenible aplicando las técnicas convencionales de simulación termodinámica. Los resultados indican que pueden obtenerse niveles de precisión parecidos utilizando ambas técnicas de modelado.

Atendiendo a estos resultados, para las aplicaciones en procesos industriales se aconseja el uso de modelos estadísticos, tanto por la especial robustez mostrada por los modelos RNA a los errores contenidos en las mediciones de las variables de entrada (factor que afecta negativamente a la precisión de los modelos termodinámicos) como por la disponibilidad limitada en el mercado de software de modelado específico para cubrir todas las diferentes tipologías de procesos industriales.

Se destaca asimismo el potencial de la metodología propuesta para su empleo como herramienta de verificación de ahorros en los contratos de rendimiento energético, que prevén la participación de las ESE, encargadas de financiar e implantar las MAE en las instalaciones de un cliente industrial y remuneradas en base a los ahorros reales obtenidos.

Por otra parte, cabe indicar la aplicabilidad de la técnica de modelado RNA para la determinación de líneas base energéticas con fines distintos a la verificación de ahorros. En este sentido, se necesita profundizar en las aplicaciones de dicha técnica orientadas a la determinación de las referencias de consumo y producción en emplazamientos industriales para la comparación de la operación real con la operación esperada de las instalaciones. Las referencias generadas podrían ser implementadas en un sistema de gestión energética avanzada de la planta y ayudarían a la identificación de las desviaciones del consumo energético con respecto al comportamiento esperable/esperado del sistema, y con ello a la detección de las causas de esas

desviaciones (prácticas ineficientes en la operación de la planta, fallos de los instrumentos de medición, etc.).

La necesidad de herramientas adecuadas para la generación de las líneas base energéticas está claramente expresada en el estándar internacional ISO 50001: 2001 para sistemas de gestión de la energía. Por esta razón debería tomarse en consideración el uso de técnicas como la propuesta en este trabajo, así como otras técnicas avanzadas que permitan el mismo nivel de precisión y fiabilidad, para el modelado de sistemas no lineales, en sustitución de los métodos que a menudo son adoptados en las instalaciones industriales, basados en suposiciones simplificadoras que no permiten una determinación rigurosa de la línea base de consumo, reduciendo así la eficacia del sistema de gestión energético implantado.

2. Fiabilidad y ventajas de los modelos RNA

De los resultados obtenidos se concluye que la precisión alcanzada con la técnica de modelado propuesta es la adecuada, permitiendo una reproducción fiel del comportamiento de la planta en su estado anterior a la implantación de las MAE, y consecuentemente una cuantificación fiable de los ahorros conseguidos.

En el curso del trabajo realizado ha sido posible detectar las principales ventajas asociadas al uso de la técnica de modelado RNA, que ponen de manifiesto su utilidad y versatilidad para la predicción de los consumos y producciones de sistemas industriales, y que se resumen a continuación:

- Altos niveles de precisión

Los niveles de error de los modelos RNA, ampliamente comentados en las secciones anteriores, son comparables y, en algunas ocasiones, incluso inferiores a los obtenidos con la más que comprobada técnica de simulación termodinámica del sistema.

- Robustez a los errores de medición

El modelado de un sistema por simulación termodinámica se basa en el comportamiento físico de los equipos de la planta. Esto puede constituir una válida ayuda para la detección de eventuales errores de medición, ya que el modelo, por medio de sus salidas, puede proporcionar valores más fiables para aquellas variables que están caracterizadas por altas incertidumbres de medición. Sin embargo, si estos errores se producen en las variables de entrada, existe el riesgo de propagación y se necesitan ajustes y/o cálculos complementarios. Los modelos RNA, por lo contrario, han mostrado una solidez satisfactoria frente a los errores de los valores medidos de las variables de entrada. Es ésta una característica destacada de las RNA que pudo apreciarse en el curso del estudio, sobre todo si se tiene en cuenta la fuerte sensibilidad de los modelos termodinámicos a los errores de medición en las variables de entrada, así como el impacto negativo sobre las

variables que se calculan a partir de esas mediciones por resolución de los balances de materia y energía basados en dichas entradas. El modelado RNA puede ser una válida ayuda para paliar este problema, debido al tratamiento "caja negra" del sistema que supone: a la hora de modelar unas variables con respecto a otras los errores ya están incluido en el modelo, de modo que pueden obtenerse resultados consistentes a partir de mediciones caracterizadas por un cierto nivel de incertidumbre. Lógicamente, esto sólo es posible cuando se trata de errores dentro de niveles aceptables, ya que la calidad de los datos sigue siendo un factor determinante también cuando se utilizan modelos RNA. Al margen de estas consideraciones, vale la pena recordar que la técnica de reconciliación de datos, que no ha sido utilizada en este trabajo, ayudaría a mejorar la calidad de los datos de entrada y contribuiría a aumentar la capacidad predictiva del modelo termodinámico desarrollado para la planta de cogeneración.

- **Practicidad y versatilidad**

Otro atractivo de los modelos RNA está constituido por su practicidad, ya que se recuerda que los modelos obtenidos están constituidos por funciones multivariadas que pueden implementarse en forma de ecuaciones y pueden fácilmente ser utilizados en diferentes ambientes de trabajo, como hojas de cálculo, herramientas de programación, etc.

- **Reducción del número de medidores necesarios**

La técnica RNA necesita de un número más reducido de medidores para la validación de los modelos y la generación de las líneas base, ya que el modelado se efectúa utilizando únicamente las variables que tienen influencia sobre los parámetros objetivo. A este respecto, cabe recordar que para el modelado RNA de la cogeneración se han utilizado 30 variables (27 medidas, 2 calculadas y una variable contador de tiempo), frente a los 54 medidores que han sido necesarios para la validación del modelo de simulación termodinámica.

- **Actualización ágil de los modelos**

La actualización de los modelos RNA, que puede ser necesaria cada vez que acontecen cambios significativos en la planta (siempre y cuando el objetivo no sea la comparación con el funcionamiento previo a dichos cambios), es menos onerosa si comparada con las operaciones de ajuste necesarias para los modelos de simulación termodinámica, ya que se ciñe a las variables objetivo del modelado, sin necesidad de recurrir a un ajuste global que incluya áreas y equipos del sistema que no son de interés para el análisis.

- **Resolución de limitaciones del simulador**

Tal y como se refleja en el curso del estudio, el uso de las RNA ha permitido paliar algunas problemáticas asociadas a las capacidades y limitaciones propias del simulador específico empleado. A ese respecto se recuerda que se han tenido que introducir algunas suposiciones simplificadoras para el modelado termodinámico de la cogeneración, cuyo efecto ha sido reducir la fidelidad de reproducción de la

operación de la planta. Es el caso de la inyección de vapor en la turbina de gas, que no puede predecirse directamente como función de los niveles de emisión de NO_x . Un segundo caso está representado por la imposibilidad de incluir las horas de funcionamiento como variables de entrada al modelo, que ha hecho necesario el ajuste manual de los parámetros de envejecimiento de los equipos, resultando en una mayor complicación a la hora de reproducir intervalos continuos de operación de la planta.

- Menor esfuerzo computacional

Con respecto a los tiempos requeridos para el cálculo, durante la fase de validación del modelo termodinámico surgió la problemática de los largos tiempos de espera para la simulación de períodos continuos de operación de la cogeneración. Sin embargo, es de señalar que esto no es un problema crítico para la determinación de la línea de base, ya que su cálculo se realiza sí en tiempo real pero con periodicidad normalmente horaria, de forma que los tiempos de respuesta del simulador son más que idóneos para este tipo de aplicación.

3. Limitaciones

Las principales limitaciones de la metodología propuesta están ligadas a la disponibilidad de mediciones, que es a la vez la fortaleza y la debilidad de la técnica propuesta. De allí que los procesos bien monitorizados como son las plantas de cogeneración sean buenas candidatas para dicha metodología, y que la falta de mediciones constituya un problema insanable a la hora de calcular ahorros.

A continuación se resumen las principales limitaciones de la técnica de modelado RNA que han sido detectadas en el curso del estudio:

- Incapacidad de predicción fuera de los rangos de entrenamiento

El principal inconveniente asociado con el modelado por RNA es la vulnerabilidad a los cambios en los parámetros de funcionamiento fuera de los rangos para los que los modelos han sido entrenados. De hecho, una característica común a los modelos estadísticos en general es la necesidad de disponer de datos de entrada que recojan fluctuaciones representativas de la operación del sistema. Las RNA no garantizan fiabilidad fuera de los rangos para las que fueron generadas y no pueden reproducirse los efectos de las variables para las que no se registraron cambios en el período de entrenamiento. Por el contrario el modelado termodinámico, al estar basado en la física del sistema, no se ve tan condicionado por la riqueza de los históricos disponibles.

Con respecto a esta limitación, se recuerda la problemática asociada al modelo del consumo de vapor en el desgasificador, cuyas prestaciones empeoran en el período de altos consumos de vapor, debiéndose principalmente a la exigua cantidad de datos disponibles para el entrenamiento en esa zona no representativa

de la operación normal de la planta (el proceso no retorna condensados). El modelo termodinámico no tardaría en reflejar los cambios en el consumo debidos a la ausencia de condensados desde el proceso. Un modelo estadístico, por lo contrario, es como si detectara que el comportamiento de la planta se aleja de lo normal y como consecuencia no es capaz de reproducir las fluctuaciones del proceso en esa zona.

- Vulnerabilidad a los errores en las variables de salida

Cuando los registros de las variables de salida son afectados por altos niveles de error, este error es insalvable por los modelos RNA, ya que las RNA se entrenan a partir de esos registros.

- Conocimiento físico del sistema y selección de la base de datos

Merece la pena una aclaración con respecto a la simplicidad y practicidad que caracteriza el desarrollo y la aplicación de los modelos RNA. Aunque la filosofía "caja negra" de la técnica RNA pueda sugerir lo contrario, el estudio propuesto pone de manifiesto que la aplicación del modelado estadístico no permite prescindir de un profundo conocimiento de la física del sistema, necesario en todas las fases del análisis, y especialmente en la de selección de las variables de influencia de los modelos. Es éste un factor de suma importancia, ya que la base de datos seleccionada afecta inevitablemente al resultado del entrenamiento de las RNA. En el caso del modelado termodinámico el problema de conocimiento físico de la planta está más bien relacionado con la construcción del modelo, siendo la selección de los datos menos crítica. De hecho, las desviaciones de las simulaciones termodinámicas de los registros medidos incluso pueden constituir una valiosa ayuda para la revisión de la base de datos seleccionada.

- Visión limitada del problema

La aplicación de técnicas estadísticas impide, en general, disponer de un modelo global que describa completamente el comportamiento termodinámico del sistema, debido a que se desarrollan modelos específicos para determinados parámetros de interés, definidos en función de los objetivos del análisis. De hecho la aplicación del modelado RNA supone la determinación "a priori" de dichos objetivos en las primeras fase del estudio, siendo necesaria su redefinición cada vez que cambien las áreas de interés del análisis. Por lo contrario, los modelos de simulación, al ser modelos deterministas basados en ecuaciones termodinámicas, necesitan de la resolución de los balances de masa y energía de todos los equipos y subsistemas de la planta, de forma que pueden emplearse posteriormente para realizar análisis de cualquier área o equipo.

Capítulo 7. **Desarrollos futuros y en curso**

1. Avances y mejoras en la metodología propuesta

En esta sección se comentan algunos aspectos de carácter técnico que quedan pendientes por explorar y cuya aplicación se cree que podría contribuir a la mejora y perfeccionamiento de la metodología propuesta.

1.1 Feature selection

Aunque el método de modelado utilizado en este trabajo son las RNA, el uso de otras técnicas no es perjudicial para la validez de la metodología propuesta. Por esta razón es aconsejable evaluar la aplicabilidad de las técnicas de “Feature Selection (FS)” (selección de características), que podrían contribuir a mejorar la etapa preliminar de cribado (“screening”) del conjunto de datos.

La FS se define como el conjunto de técnicas orientadas a detectar las “características” (más propiamente variables en nuestro caso) relevantes y descartar las irrelevantes, con el objetivo de generar un subconjunto de variables más reducido que permita describir de forma adecuada un problema dado. Esta identificación de las variables más influyentes se está volviendo cada vez más indispensable, teniendo en cuenta las actuales dimensiones, a menudo elevadas, de los conjuntos de datos disponibles procedentes de los sistemas de control distribuido de las plantas industriales, tanto a nivel de número de muestras como de variables monitorizadas. El objetivo y el resultado de la aplicación de las herramientas FS es la clasificación de las variables en función de su relevancia e influencia sobre el objetivo.

En este trabajo se ha decidido no aplicar las técnicas FS debido a que en algunos estudios se ha cuestionado la eficacia de esa herramienta cuando se aplica a la técnica de modelización RNA [121]. No obstante, e independientemente de las técnicas específicas de modelado propuestas, se trata de un tema clave a profundizar, sobre todo considerando las aplicaciones a procesos industriales para los que se carece de conocimiento físico a priori. En estos casos quedaría pendiente estandarizar el proceso de preselección del conjunto de variables de entrada al modelo (fase 3.3 de la metodología propuesta en este trabajo). En el caso en que se seleccionen técnicas de modelado distintas de las RNA, es de esperar que la FS mejore de forma relevante la fase 3.3 del análisis y su aplicación podría dar lugar a una modificación sustancial de la metodología, al poderse sustituir el método iterativo propuesto para la selección de las variables de influencia (fase 6.2, basada en el método de importancia de los predictores) por un proceso de selección “a priori”.

Con respecto a la indudable practicidad de estos métodos de “simple etapa”, en los que la selección de las variables se efectúa de una vez sin procesos recursivos, siempre deberán tenerse en cuenta los riesgos asociados a este tipo de análisis de “no retorno”, y los resultados habrán de ser revisados críticamente y verificados sin perder de vista los principios físicos que rigen el comportamiento del sistema.

1.2 Forgetting factor

Las líneas base de consumos y producciones de energía generadas en este trabajo tienen como objetivo la reproducción del comportamiento de una planta antes de que en ella se acometieran una serie de cambios.

En otras aplicaciones, como ya se ha tenido oportunidad de comentar, puede que el objetivo de la línea base sea reproducir la operación estándar y/o deseada de la planta bajo las condiciones actuales, de forma que su utilidad sería, entre otras, la detección de anomalías operativas y desviaciones de la línea de consumo esperable del sistema. En este caso el acontecimiento de cambios en el sistema obligaría al re-entrenamiento de los modelos, si el fin es seguir prediciendo el comportamiento de la planta bajo su configuración actual.

En el marco de estos procesos de re-entrenamiento, será interesante explorar la posibilidad de incluir herramientas que permitan aumentar el dinamismo y flexibilidad de los modelos RNA y su habilidad de captación de las tendencias del sistema a medio y largo plazo. Entre los posibles métodos aplicables para ese fin, se cree que podrían obtenerse resultados interesantes con la introducción del “forgetting factor” (factor de olvido) en los algoritmos de minimización del error. Con la introducción de esta herramienta, los nuevos entrenamientos de los modelos, que incluso podrían realizarse on-line de forma periódica, siempre estarían priorizando la información contenida en los registros más recientes, lo cual aumentaría la precisión de reproducción de las nuevas tendencias reduciendo de forma gradual el factor de importancia asociado a los históricos más antiguos.

1.3 Ajuste de los porcentajes de entrenamiento

En la fase de determinación de las prestaciones de los modelos RNA ([fase 6.5](#)) ha quedado manifiesta la reducción de precisión de predicción en los tramos de operación que no reflejan un comportamiento consuetudinario del sistema y para los cuales no se dispone de muchos históricos.

A ese respecto se recuerda el modelo del consumo de vapor en el desgasificador, cuyas prestaciones empeoran en el período de altos consumos de vapor. Dichos consumos, de hecho, ocurren cuando el proceso productivo de la refinería no retorna condensados a la planta de cogeneración, lo cual no se corresponde al funcionamiento normal de la unidad.

Para intentar paliar, aunque parcialmente, la problemática de la escasa disponibilidad de datos, un posible desarrollo de la metodología propuesta podría incluir el empleo de herramientas de programación más flexibles para el entrenamiento de los modelos, que permitan un reparto y ajuste selectivo de los porcentajes de entrenamientos y la selección de porcentajes específicos adaptados a los distintos tramos del período de entrenamiento. Según este principio, para el período de altos consumos de vapor en el desgasificador, se reducirían los porcentajes de datos asignados al conjunto de test y al

subconjunto de validación cruzada, y se dejaría un número mayor de datos a disposición para el entrenamiento.

2. Aspectos ligados a la implantación de contratos ESE

Considerando la aplicabilidad de la metodología desarrollada como instrumento de cuantificación de ahorros en los contratos de rendimiento energético, será necesario el análisis detallado y la definición de las cláusulas contractuales que permitan cubrir los posibles escenarios de desacuerdo entre las dos partes y establecer inequívocamente las acciones necesarias para resolverlos.

Con respecto a los aspectos puramente técnicos a prever en los contratos, se destaca la necesidad de la actualización de los modelos RNA generados y su adaptación a los casos en los que se hayan producido cambios en el sistema durante el período de demostración de ahorro, es decir, durante el período post-retrofit. Estos casos habrán de analizarse con especial atención, ya que las modificaciones acontecidas, dependiendo de cuál sea su entidad e impacto, podrían obligar no sólo al re-entrenamiento de los modelos sino también a la revisión de la misma estructura de las RNA (número de neuronas y de capas ocultas) e incluso de las variables de influencia seleccionadas.

De la misma forma deberán tenerse en cuenta otros tipos de situaciones que puedan afectar a la fiabilidad de los modelos, tales como la sustitución de los instrumentos de medición en la planta, lo cual también requiere el re-entrenamiento de los modelos. En este sentido, deberán definirse los criterios que determinen la duración mínima de los períodos de adquisición de datos antes de que los modelos puedan ser re-entrenados, de modo que los nuevos datos almacenados contengan la información suficiente para que se pueda reproducir de forma fiable el funcionamiento del sistema tras las modificaciones. Atendiendo a esta forma de proceder, no se excluye que se tengan que prever cláusulas que contemplen la validación retroactiva de los ahorros en lugar que en tiempo real, permitiendo el cumplimiento de los tiempos de espera para la generación de modelos con suficiente capacidad de predicción.

3. Nuevas aplicaciones en curso

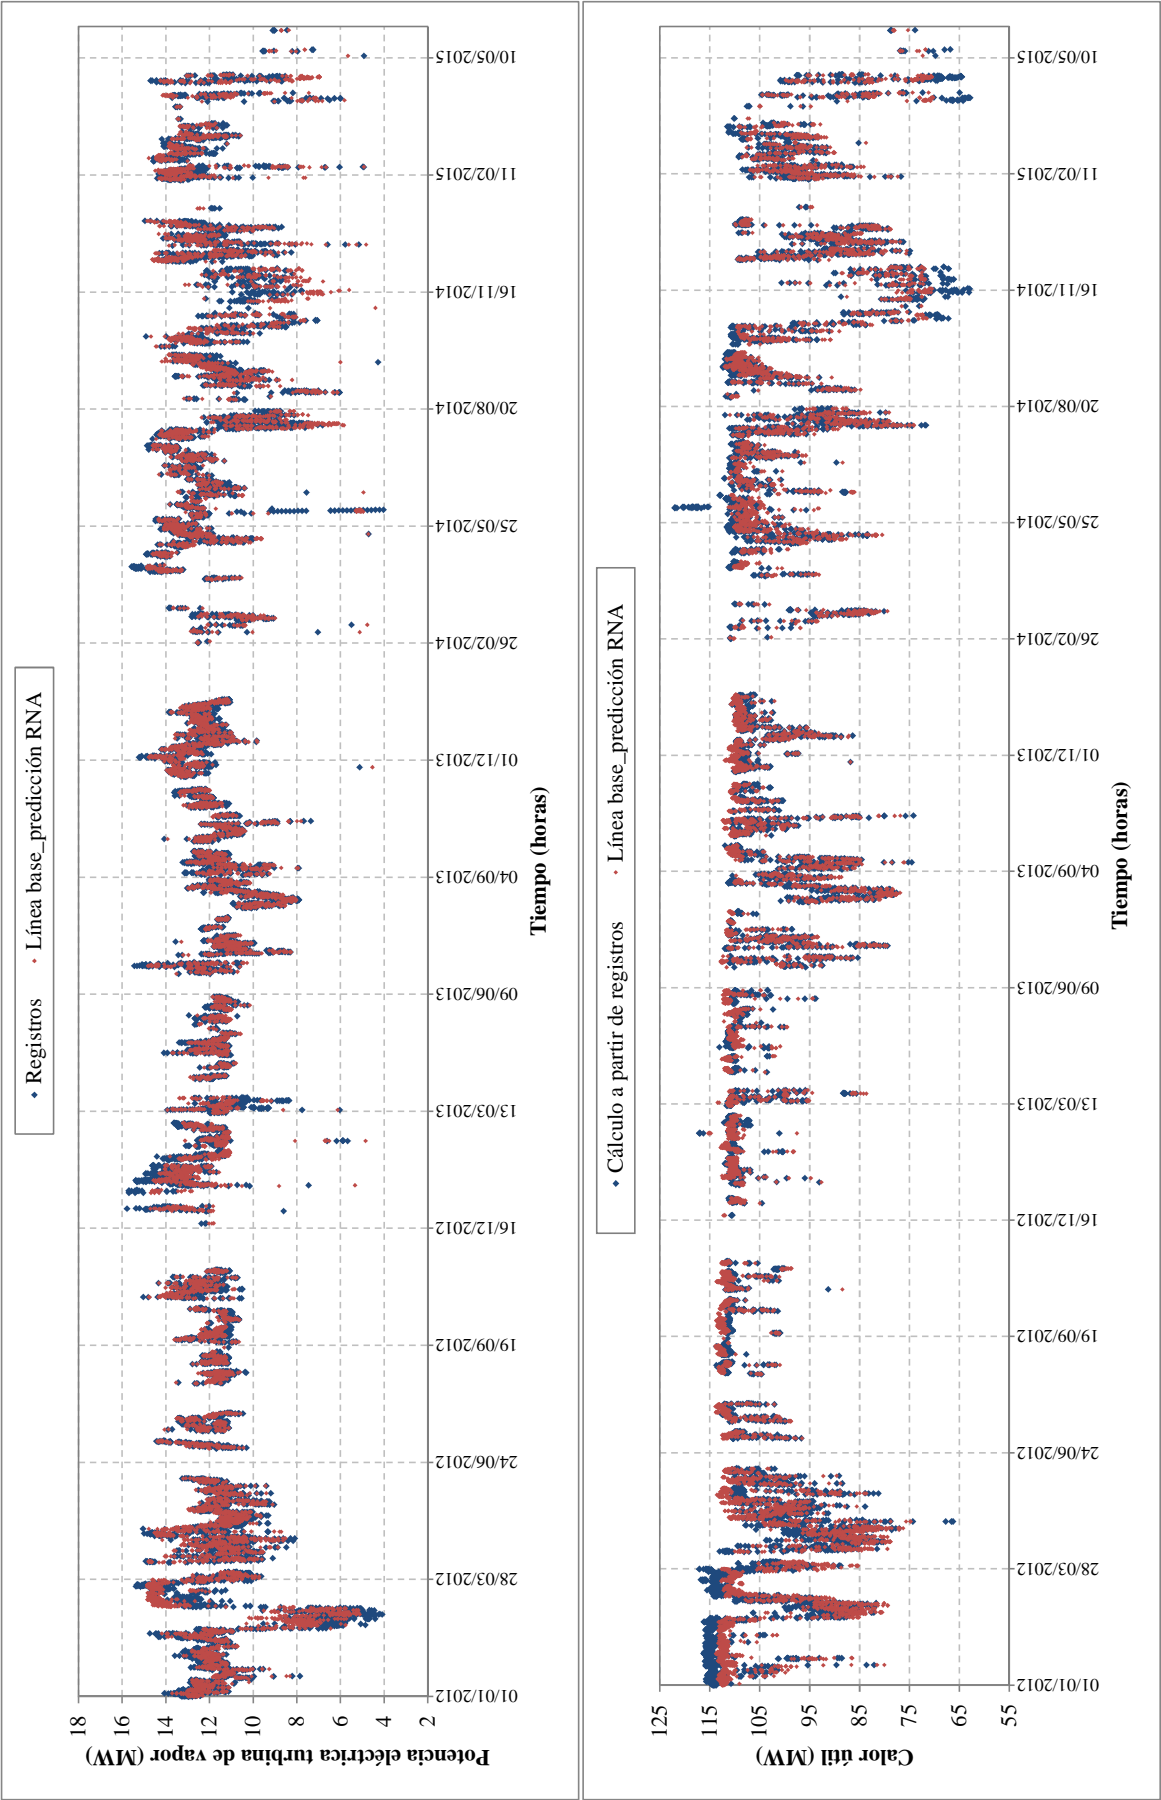
Aparte de los resultados obtenidos en este trabajo, como es lógico, se necesitarán más pruebas concretas que validen la aplicabilidad de la metodología desarrollada y su efectividad deberá ser comprobada para aplicaciones industriales distintas de la propuesta. En este sentido, deberían obtenerse modelos de consumo energético basados en RNA para muchos otros casos, identificando y abordando las problemáticas específicas que caracterizan la gran variedad de procesos productivos existentes en la industria.


El autor de este trabajo está actualmente participando en algunos proyectos cuyo alcance está muy relacionado con el trabajo propuesto y que pueden ser considerados, bajo algunos aspectos, un desarrollo del mismo.

3.1 Líneas base de comportamiento esperado de la cogeneración

Está actualmente en curso de finalización el desarrollo de unos modelos RNA para la reproducción del comportamiento estándar de la misma planta de cogeneración objeto de este trabajo. El objetivo del proyecto es la generación de las líneas base para los principales parámetros energéticos que concurren en la definición del beneficio económico de explotación de la unidad. Los modelos generados se utilizan para detectar eventuales desviaciones de la operación de la planta de la referencia de comportamiento. La peculiaridad del estudio consiste en la cantidad relevante de históricos utilizados, ya que las RNA han sido entrenadas sobre un conjunto de datos en base horaria correspondiente a un período de 3,5 años, desde la fecha 01 enero 2012 hasta el día 02 junio 2015.

En la [figura 60](#) se muestran las líneas base obtenidas para los principales parámetros energéticos que concurren al beneficio de la cogeneración.





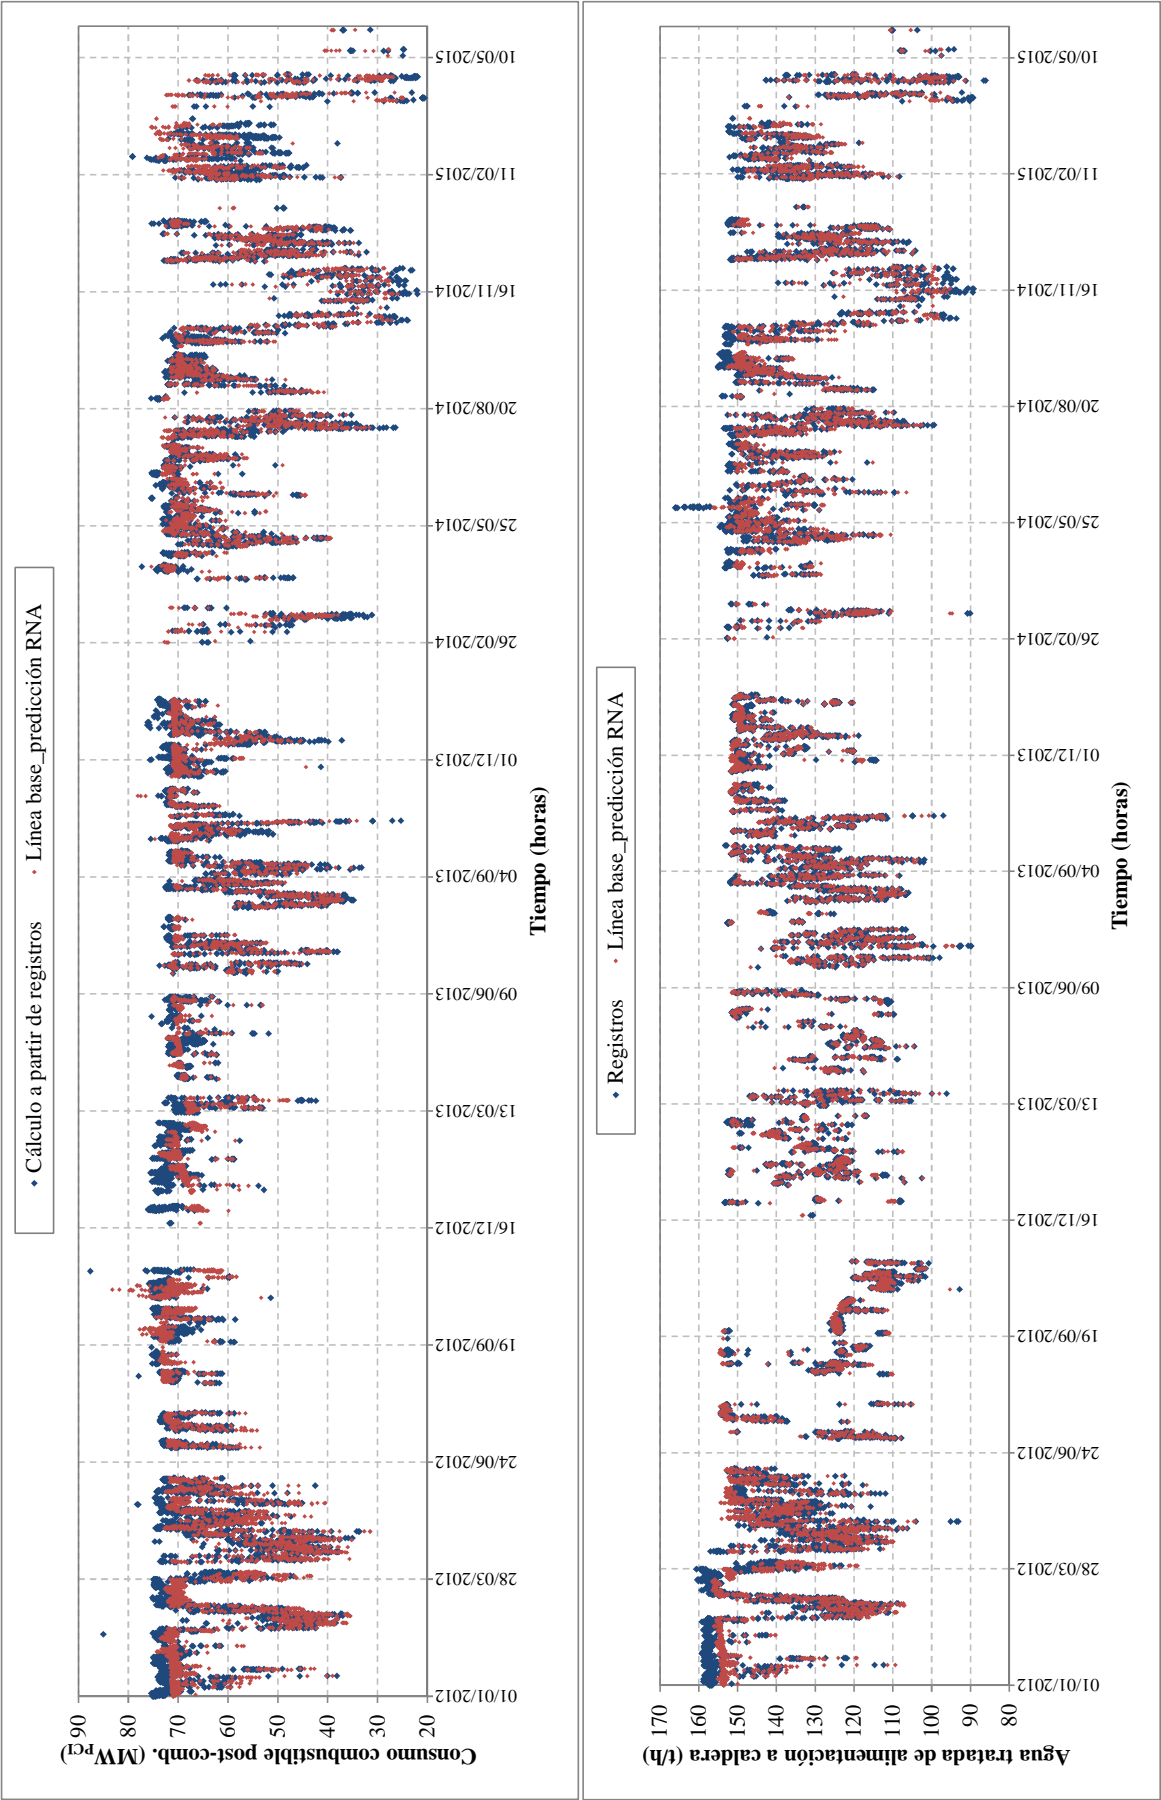


Figura 60. Líneas base de comportamiento energético de la cogeneración.

Las operaciones de filtrados realizadas determinaron una reducción del número de registros desde los 29.960 iniciales hasta 13.757, que corresponde a la eliminación del 54% de los datos. La ingente cantidad de registros se debe a los tipos de filtrados implementados en la aplicación desarrollada, cuyo objetivo es la utilización por parte de usuarios finales ajenos al desarrollo de dicha aplicación. Por esta razón se utilizan filtrados en tiempo real de tipo estándar, basados en límites superiores e inferiores consensuados con el usuario final, que tienen por un lado la ventaja de una mayor manejabilidad y robustez de los modelos y, por el otro, el inconveniente de eliminar registros que podrían salvarse mediante un análisis más crítico de la base de datos.

Al margen de estas consideraciones, los resultados indican un buen comportamiento de los modelos obtenidos, y cabe observar que la capacidad de predicción se ve algo afectada por los cambios acontecidos en la planta en el largo período de entrenamiento (peor reproducción de los históricos en el período inicial). Como puede observarse, no se ha generado una línea base para la electricidad generada en la turbina de gas. Esta forma de proceder responde a las indicaciones del personal dedicado a la supervisión de la operación planta, que ha expresado la voluntad de que dicha línea base coincida con los datos reales, ya que la regulación de la carga eléctrica de la turbina de gas es un parámetro objeto de especial cuidado que se efectúa atendiendo al criterio del máximo beneficio y por ello no necesita de línea base.

En la [figura 61](#) se muestra la línea base del beneficio económico de la unidad, que se obtiene por combinación de las predicciones de los modelos anteriores tras la aplicación de los correspondientes precios de la energía (electricidad y vapor) y utilities (agua).

Las líneas base generadas pueden ser utilizadas como una válida herramienta para la predicción del comportamiento esperado de la unidad, permitiendo la detección en primer lugar de las eventuales desviaciones de la referencia de beneficio, en segundo lugar de cuáles de los parámetros energéticos que lo componen se está desviando de la referencia y, por último, de si existen desviaciones en los valores operativos de las variables manipulables que han sido utilizadas para el modelado de dichos parámetros.




Figura 61. Línea base del beneficio económico de explotación de la cogeneración.

3.2 Modelado y optimización de una planta de reformado de hidrógeno

Otro proyecto en curso de realización en el cual está participando el autor de este trabajo consiste en el modelado y la siguiente optimización de una unidad de reformado de hidrógeno a partir de gas natural. El alcance del trabajo prevé el modelado de la planta a partir de datos históricos mediante RNA y su optimización a través del algoritmo genético, una herramienta que permite la optimización de los valores de las variables de influencia manipulables a partir de combinaciones aleatorias de dichas variables (bajo las debidas restricciones) y la sucesiva aplicación de operadores genéticos inspirados en la teoría evolutiva según el criterio de maximización de unas determinadas funciones objetivo (funciones de calidad o de “fitness”).

Al ser alto el nivel de complejidad que caracteriza el proceso productivo objeto del estudio, se considera que se trata de un caso idóneo para explorar el potencial de las técnicas FS, cuya aplicación será dirigida a la identificación de las variables de influencia de interés y a cuantificar su efecto sobre los objetivos del modelado. En esta fase de selección, cuya importancia y criticidad ha sido resaltada anteriormente, no se descarta que se efectuará algún tipo de validación de los resultados obtenidos, que podría basarse en análisis de sensibilidad posteriores a efectuarse sobre los modelos generados. En dichos análisis se observarían las reacciones de los modelos, en términos de capacidad de predicción alcanzada, eliminando algunas de las variables previamente seleccionadas con la técnica FS, para comprobar sus efectos de forma definitiva. De esta forma se cree que se podría conferir mayor nivel de robustez y fiabilidad al proceso de selección de variables, en el cual se estaría aprovechando el potencial de las técnicas FS del tipo “a priori” sin renunciar a una validación de tipo iterativo como es la que se propone en este trabajo.

Bibliografía

- [1] European Commission. Energy Efficiency Plan 2011. Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions, Brussels 2011.
- [2] European Commission. An Integrated industrial policy for the globalisation era putting competitiveness and sustainability at centre stage. Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions, Brussels 2010.
- [3] European Commission. A European strategy energy technology plan (SET-plan). 'Towards a low carbon future'. Communication from the Commission to the Council, the European Parliament, the European Economic and Social Committee and the Committee of the Regions, 2007.
- [4] European Commission, Joint Research Centre, Institute for Prospective and Technological Studies. Best available techniques reference document on energy efficiency, 2009. <<http://eippcb.jrc.es/reference/ene.html>>.
- [5] Efficiency Valuation Organization (EVO). International Performance Measurement and Verification Protocol. Concepts and Options for Determining Energy and Water Savings, 2012;1 www.evo-world.org
- [6] Reichl J, Kollmann A. The baseline in bottom-up energy efficiency and saving calculations – A concept for its formalization and a discussion of relevant options. *Applied Energy* 2011;88:422-31.
- [7] Pratt J, Donahue J. U.S. EPA state clean energy and climate program, clean energy lead by example guide: strategies, resources, and action steps for state programs. Stratus Consulting, Inc. 2009 www.epa.gov/cleanenergy/energy-programs/state-and-local/index.html
- [8] Kissock JK, Eger C. Measuring industrial energy savings. *Applied Energy* 2008;85:347-61.
- [9] Dalgleish AZ, Grobler LJ. Measurement and verification of a motor sequencing controller on a conveyor belt. *Energy* 2003;28:913-27.
- [10] Velázquez D, González R, Pérez L, Gallego LM, Monedero I, Biscarri F. Development of an energy management system for a naphtha reforming plant: a data mining approach. *Energy Conversion and Management* 2013;67:217-25.
- [11] Motlaghi S, Jalali F, Ahmadabadi MN. An expert system design for a crude oil distillation column with the neural networks model and the process optimization using genetic algorithm framework. *Expert Systems with Applications* 2008;35:1540-5.
- [12] Yanmin W, Pingjing Y. Simulation and optimization for thermally coupled distillation using artificial neural network and genetic algorithm. *Chinese Journal of Chemical Engineering* 2003;11:307-11.
- [13] Nascimento CAO, Giudici R, Guardani R. Neural network based approach for optimization of industrial chemical processes. *Computers & Chemical Engineering* 2000;24:2303-14.
- [14] Liao LCK, Yang TCK, Tsai MT. Expert system of a crude oil distillation unit for process optimization using neural networks. *Expert Systems with Applications* 2004;26:247-55.
- [15] Khayet M, Cojocaru C. Artificial neural network modelling and optimization of desalination by air gap membrane distillation. *Separation and Purification Technology* 2012;86:171-82.
- [16] Chavan PD, Sharma T, Mall BK, Rajurkar BD, Tambe SS, Sharma BK, Kulkarni BD. Development of data-driven models for fluidized-bed coal gasification process *Fuel* 2012;93:44-51.
- [17] Olanrewaju OA, Jimoh AA. Review of energy models to the development of an efficient industrial energy model. *Renewable and Sustainable Energy Reviews* 2014;30:661-71.

- [18] Monedero I, Biscarri F, León C, Guerrero JI, González R, Pérez L. Decision system based on neural networks to optimize the energy efficiency of a petrochemical plant. *Expert Systems with Applications* 2012;39:9860-7.
- [19] Nikpey H, Assadi M, Breuhaus P, Mørkved P.T. Experimental evaluation and ANN modeling of a recuperative micro gas turbine burning mixtures of natural gas and biogas. *Applied Energy* 2014;117:30-41.
- [20] Fast M, Palme T. Application of artificial neural networks to the condition monitoring and diagnosis of a combined heat and power plant. *Energy* 2010;35:1114-20.
- [21] Boccaletti C, Cerri G, Seyedan B. A neural network simulator of a gas turbine with a waste heat recovery section. *Journal of Engineering for Gas Turbines and Power* 2001;123:371-6.
- [22] Smrekar J, Assadi M, Fast M, Kuštrin I, De S. Development of artificial neural network model for a coal-fired boiler using real plant data. *Energy* 2009;34:144-52.
- [23] Cerri G, Borghetti S, Salvini C. Neural management for heat and power cogeneration plants. *Engineering Application of Artificial Intelligence* 2006;19:721-30.
- [24] Moghavvemi M, Yang SS, Kashem, MA. A practical neural network approach for power generation automation. *Proceedings of Energy Management and Power Delivery. International Conference* 1998;1:305-10.
- [25] De S, Kaiadi M, Fast M, Assadi M. Development of an artificial neural network model for the steam process of a coal biomass co-fired combined heat and power (CHP) plant in Sweden. *Energy* 2007;32:2099-109.
- [26] Fantozzi F, Desideri U. Simulation of power plant transients with artificial neural networks: application to an existing combined cycle. *Proceedings of the Institution of Mechanical Engineers* 1998;212:299-313.
- [27] Pan L, Flynn D, Cregan M. Statistical model for power plants performance monitoring and analysis. *Universities Power Engineering Conference 2007. UPEC 2007. 42nd International Conference*, 121-6.
- [28] Smrekar J, Pandit D, Fast M, Assadi M, De S. Prediction of power output of a coal-fired power plant by artificial neural network. *Neural Computing & Applications* 2010;19:725-40.
- [29] Lu S, Hogg BW. Dynamic and nonlinear modelling of power plant by physical principles and neural networks. *International Journal of Electrical Power & Energy Systems* 2000;22:67-78.
- [30] Romero CE, Shan J. Development of an artificial neural network-based software for prediction of power plant canal water discharge temperature. *Expert Systems with Applications* 2005;29:831-8.
- [31] Hsu CT, Chuang, HJ, Chen CS. Adaptive load shedding for an industrial petroleum cogeneration system. *Expert Systems with Applications* 2011;38:13967-74.
- [32] Liang-yu M, Jian-qiang G, Bing-shu W. Fault intelligent diagnosis for high pressure feed water heater system of a 300 MW coal-fired power unit based on improved BP Neural network. *IEEE Transactions on Neural Networks* 2002;15:35-9.4
- [33] Tunckaya Y, Koklukaya E. Comparative analysis and prediction study for effluent gas emissions in a coal-fired thermal power plant using artificial intelligence and statistical tools. *Journal of the Energy Institute* 2014;dx.doi.org/10.1016/j.joei.2014.07.003.
- [34] Ferretti G, Piroddi L. Estimation of NOx emissions in thermal power plants using neural networks. *Journal of Engineering for Gas Turbines and Power* 2001;123:465-71.
- [35] Tronci S, Baratti R, Servida A. Monitoring pollutant emissions in a 4.8 MW power plant through neural network. *Neurocomputing* 2002;43:3-15.
- [36] Azid IA, Ripin ZM, Aris MS, Ahmad AL, Seetharamu KN, Yusoff RM. Predicting combined-cycle natural gas power plant emissions by using artificial neural networks. *TENCON Proceedings* 2000;3:512-7.

- [37] Du X, Liu L, Xi X, Yang L, Yang Y, Liu Z, Zhang X, Yu C, Du J. Back pressure prediction of the direct air cooled power generating unit using the artificial neural network model. *Applied Thermal Engineering* 2011;31:3009-14.
- [38] Jia, R., Xu, H. ANN models for steam turbine power output toward condenser circulating water flux. Paper presented at the International Conference on Intelligent Computation Technology and Automation, ICICTA 2010;1:719-21.
- [39] Yu CL, Lu YZ, Chu J. A "load forecasting - dispatching" integration system for multiple boilers in thermal power plants. *Power Engineering and Automation Conference (PEAM). IEEE* 2011;3:5-10.
- [40] Prieto MM, Montañés E, Menéndez O. Power plant condenser performance forecasting using a non-fully connected artificial neural network. *Energy* 2001;26:65-79.
- [41] Tunckaya Y, Koklukaya E. Comparative prediction analysis of 600MWe coal-fired power plant production rate using statistical and neural-based models. *Journal of the Energy Institute* 2014;dx.doi.org/10.1016/j.joei.2014.06.007.
- [42] Hajabdollahi F, Hajabdollahi Z, Hajabdollahi H. Soft computing based multi-objective optimization of steam cycle power plant using NSGA-II and ANN. *Applied Soft Computing* 2012;12:3648-55.
- [43] Ma J, Wang BS, Ma YG. Ann-based real-time parameter optimization via GA for superheater model in power plant simulator. *Proceedings of the 7th International Conference on Machine Learning and Cybernetics (ICMLC)* 2008;4:2269-73.
- [44] Hao Z, Qian X, Cen K, Fan J. Optimizing pulverized coal combustion performance based on ANN and GA. *Fuel Processing Technology* 2003;85:113-24.
- [45] Suresh, MVJJ, Reddy KS, Kolar AK. ANN-GA based optimization of a high ash coal-fired supercritical power plant. *Applied Energy* 2011;88:4867-73.
- [46] Wanga J, Sun Z, Dai Y, Ma S. Parametric optimization design for supercritical CO₂ power cycle using genetic. *Applied Energy* 2010;87:1317-24.
- [47] Flynn D, Ritchie J, Cregan M. Data mining techniques applied to power plant performance monitoring. Paper presented at 16th IFAC World Congress, Prague, Czech Republic 01/07/2005.
- [48] Fast M, Palmé T, Genrup M. A novel approach for gas turbine condition monitoring combining cusum technique and artificial neural network. *Proceedings of the ASME Turbo Expo 2009, Florida, USA.*
- [49] Lazzaretto A, Toffolo A. Analytical and neural network models for gas turbine design and off-design simulation. *International Journal of Applied Thermodynamics* 2001;4:173–82.
- [50] Asgari H, Chen XQ, Menhaj MB, Sainudiin R. Artificial neural network–based system identification for a single-shaft gas turbine. *Journal of Engineering for Gas Turbines and Power* 2013;135:092601/1-7.
- [51] Fast M, Assadi M, De S. Development and multi-utility of an ANN model for an industrial gas turbine. *Applied Energy* 2009;86:9-17.
- [52] Barad SG, Ramaiahb PV, Giridhara RK, Krishnaiahb G. Neural network approach for a combined performance and mechanical health monitoring of a gas turbine engine. *Mechanical Systems and Signal Processing* 2012;27:729-42.
- [53] Fast M, De S, Assadi M. Condition based maintenance of gas turbines using simulation data and artificial neural network: a demonstration of feasibility. *ASME Turbo Expo, Berlin, Germany* 2008:153-61.
- [54] Cortés O, Urquiza G, Hernández JA. Optimization of operating conditions for compressor performance by means of neural network inverse. *Applied Energy* 2009;86:2487-93.
- [55] Joly RB, Ogaji SOT, Singh R, Probert SD. Gas-turbine diagnostics using artificial neural-networks for a high bypass ratio military turbofan engine. *Applied Energy* 2004;78:397-418.
- [56] Kong CD, Goo YJ. GUI type fault diagnostic program for a turboshaft engine using fuzzy and neural networks. *International Journal of Turbo & Jet-Engines* 2011;28:31-9.

- [57] Olausson P, Häggstahl D, Arriagada J, Dahlquist E, Assadi M. Hybrid model of an evaporative gas turbine power plant utilizing physical models and artificial neural network. Proceedings of the ASME Turbo Expo 2003, Atlanta, Georgia, USA, 1.
- [58] Bettocchi R, Pinelli M, Spina PR, Venturini M. Artificial intelligence for the diagnostics of gas turbines–Part I: Neural network approach. *Journal of Engineering for Gas Turbines and Power* 2007;129:711-9.
- [59] Kong CD, Ki JY, Kang MC, Kho SH. Intelligent performance diagnostics of a gas turbine engine using user-friendly interface neural networks. *Aircraft Engineering and Aerospace Technology. An International Journal* 2004;76:391-7.
- [60] Simani S, Fantuzzi C. Fault diagnosis in power plant using neural networks. *Information Sciences* 2000;127:125-36.
- [61] Volponi AJ, DePold H, Ganguli R, Daguang C. The use of Kalman filter and neural network methodologies in gas turbine performance diagnostics: a comparative study. *Journal of Engineering for Gas Turbines and Power* 2003;125:917-24.
- [62] Arriagada J, Genrup M, Loberg A, Assadi M. Fault diagnosis system for an industrial gas turbine by means of neural networks. Proceedings of the International Gas Turbine Congress (IGTC). Tokyo, Japan 2003, Paper IGTC2003Tokyo TS-001.
- [63] Abdul Ghafir MF, Li YG, Wang L. Creep life prediction for aero gas turbine hot section component using artificial neural networks. *Journal of Engineering for Gas Turbines and Power* 2014;136: 031504-1-9.
- [64] Palmé T, Breuhaus P, Assadi M, Klein A, Kim M. New Alstom monitoring tools leveraging artificial neural network technologies. ASME Turbo Expo 2011; Paper no. GT2011-45990.
- [65] Sisworahardjo NS, El-Sharkh MY, Alamb MS. Neural network controller for microturbine power plants. *Electric Power Systems Research* 2008;78:1378–84.
- [66] Rusinowski H, Stanek W. Neural modelling of steam boilers. *Energy Conversion and Management* 2007;48:2802-9.
- [67] Chong AZS, Wilcox SJ, Ward J. Prediction of gaseous emissions from a chain grate stoker boiler using artificial neural networks of ARX structure. *IEE Proceedings-Science, Measurement and Technology* 2001;148:95-102.
- [68] Zhou H, Cen K, Fan J. Modeling and optimization of the NO_x emissions characteristics of a tangentially fired boiler with artificial neural networks. *Energy* 2004;29:167-83.
- [69] Liukkonen M, Heikkinen M, Hiltunen T, Halikka E, Kuivalainen R, Hiltunen Y. Artificial neural networks for analysis of process states in fluidized bed combustion. *Energy* 2011;36:339-47.
- [70] Bekat T, Erdogan M, Inal F, Genc A. Prediction of the bottom ash formed in a coal-fired power plant using artificial neural networks. *Energy* 2012;45:882-7.
- [71] Teruel E, Cortes C, Diez LI, Arauzo I. Monitoring and prediction of fouling in coal-fired utility boilers using neural networks. *Chemical Engineering Science* 2005;60:5035-48.
- [72] Arriagada J, Costantini M, Olausson P, Assadi M, Torisson T. Artificial neural network model for a biomass-fuelled boiler. Proceedings of the ASME Turbo Expo 2003, Atlanta, Georgia, USA.
- [73] Romeo LM, Gareta R. Neural network for evaluating boiler behaviour. *Applied Thermal Engineering* 2006;26:1530-6.
- [74] Calisto H, Martins N, Afgan N. Diagnostic system for boilers and furnaces using CFD and neural networks. *Expert Systems with Applications* 2008;35:1780–7.
- [75] Esen H, Inalli M. Modelling of a vertical ground coupled heat pump system by using artificial neural networks. *Expert Systems with Applications* 2009;36:10229-38.
- [76] Kizilkan Ö. Thermodynamic analysis of variable speed refrigeration system using artificial neural networks. *Expert Systems with Applications* 2011;38:11686-92.

- [77] Hosoz M, Ertunc HM, Bulgurcu H. Performance prediction of a cooling tower using artificial neural network. *Energy Conversion and Management* 2007;48:1349-59.
- [78] Abbassi A, Bahar L. Application of neural network for the modeling and control of evaporative condenser cooling load. *Applied Thermal Engineering* 2005;25:3176-86.
- [79] Ghorbanian K, Gholamrezaei M. An artificial neural network approach to compressor performance prediction. *Applied Energy* 2009;86:1210-21.
- [80] Tian Z, Gu B, Yang L, Lu Y. Hybrid ANN-PLS approach to scroll compressor thermodynamic performance prediction. *Applied Thermal Engineering* 2015;77:113-20.
- [81] Satish S, Setty YP. Modeling of a continuous fluidized bed dryer using artificial neural networks. *International Communications in Heat and Mass Transfer* 2005;32:539-47.
- [82] Chen W, Tsutsumi A, Lin H, Otawara K. Modeling nonlinear dynamics of circulating fluidized beds using neural networks. *China Particuology* 2005;3:84-89.
- [83] Yap WK, Karri V. Comparative analysis of artificial neural networks and dynamic models as virtual sensors. *Applied Soft Computing* 2013;13:181-8.
- [84] Tasdemir S, Saritas I, Ciniviz M, Allahverdi N. Artificial neural network and fuzzy expert system comparison for prediction of performance and emission parameters on a gasoline engine. *Expert Systems with Applications* 2011;38:13912-23.
- [85] Çay Y, Çiçek A, Kara F, Sağiroğlu S. Prediction of engine performance for an alternative fuel using artificial neural network. *Applied Thermal Engineering* 2012;37:217-25.
- [86] Kiani MKD, Ghobadian B, Tavakoli T, Nikbakht AM, Najafi G. Application of artificial neural networks for the prediction of performance and exhaust emissions in SI engine using ethanol-gasoline blends. *Energy* 2010;35:65-9.
- [87] Roy S, Banerjee R, Das AK, Bose PK. Development of an ANN based system identification tool to estimate the performance-emission characteristics of a CRDI assisted CNG dual fuel diesel engine. *Journal of Natural Gas Science and Engineering* 2014;21:147-58.
- [88] Mariani F, Grimaldi CN, Battistoni M. Diesel engine NO_x emissions control: An advanced method for the O₂ evaluation in the intake flow. *Applied Energy* 2014;113:576-88.
- [89] Oğuz H, Saritas I, Baydan HE. Prediction of diesel engine performance using biofuels with artificial neural network. *Expert Systems with Applications* 2010;37:6579-86.
- [90] Canakci, M., Ozsezen, A.N., Arcaklioglu, E., Erdil, A. (2009). Prediction of performance and exhaust emissions of a diesel engine fueled with biodiesel produced from waste frying palm oil. *Expert Systems with Applications*, 36, 9268-9280.
- [91] Oliveira MV, Soares de Almeida JC. Application of artificial intelligence techniques in modeling and control of a nuclear power plant pressurizer system. *Progress in Nuclear Energy* 2013;63:71-85.
- [92] Gomes CR, Medeiros, JACC. Neural network of Gaussian radial basis functions applied to the problem of identification of nuclear accidents in a PWR nuclear power plant. *Annals of Nuclear Energy* 2015;77:285-93.
- [93] Rashidi MM, Galanis N, Nazari F, Basiri Parsa A, Shamekhi L. Parametric analysis and optimization of regenerative Clausius and organic Rankine cycles with two feedwater heaters using artificial bees colony and artificial neural network. *Energy* 2011;36:5728-40.
- [94] Arslan O, Yetik O. ANN based optimization of supercritical ORC-Binary geothermal power plant: Simav case study. *Applied Thermal Engineering* 2011;31:3922-8.
- [95] Chávez AU, Muñoz R, Durón SM, Ferraro M, Brunaccini G, Sergi F, Antonucci V, Arriaga LG. High power fuel cell simulator based on artificial neural network. *International Journal of Hydrogen Energy* 2010;35:12125-33.

- [96] Wu XJ, Zhu XJ, Cao GY, Tu HY. Modeling a SOFC stack based on GA-RBF neural networks identification. *Journal of Power Sources* 2007;167:145-50.
- [97] Hatti M, Tioursi M. Dynamic neural network controller model of PEM fuel cell system. *International Journal of Hydrogen Energy* 2009;34:5015-21.
- [98] Sözen A, Akçayol MA. Modelling (using artificial neural-networks) the performance parameters of a solar-driven ejector-absorption cycle. *Applied Energy* 2004;79:309-25.
- [99] Shukur OB, Lee, MH. Daily wind speed forecasting through hybrid KF-ANN model based on ARIMA. *Renewable Energy* 2015;76:637-47.
- [100] Yeh WC, Yeh YM, Chang PC, Ke YC, Chung V. Forecasting wind power in the Mai Liao wind farm based on the multi-layer perceptron artificial neural network model with improved simplified swarm optimization. *International Journal of Electrical Power & Energy Systems* 2014;55:741-8.
- [101] Ghadi MJ, Gilani SH, Afrakhteh H, Baghrmian, A. A novel heuristic method for wind farm power prediction: A case study. *Electrical Power and Energy Systems* 2014;63:962-70.
- [102] Vargas A, Minchala LI, Zhang Y, Garza LE, Calle ER. Model-based fault-tolerant control to guarantee the performance of a hybrid wind-diesel power system in a microgrid configuration. *Procedia Computer Science* 2013;19:712-9.
- [103] Karamirad M, Omid M, Alimardani R, Mousazadeh H, Navid Heidari S. ANN based simulation and experimental verification of analytical four- and five-parameters models of PV modules. *Simulation Modelling Practice and Theory* 2013;34:86-98.
- [104] Jiang LL, Nayanassiri DR, Maskell DL, Vilathgamuwa DM. A hybrid maximum power point tracking for partially shaded photovoltaic systems in the tropics. *Renewable Energy* 2015;76:53-65.
- [105] Yap WK, Karri V. An off-grid hybrid PV/diesel model as a planning and design tool, incorporating dynamic and ANN modelling techniques. *Renewable Energy* 2015;78:42-50.
- [106] Castro A, Carballo R, Iglesias G, Rabuñal JR. Performance of artificial neural networks in nearshore wave power prediction. *Applied Soft Computing* 2014;23:194-201.
- [107] Tardast A, Rahimnejad M, Najafpour G, Ghoreyshi A, Premier GC, Bakeri G, Oh SE. Use of artificial neural network for the prediction of bioelectricity production in a membrane less microbial fuel cell. *Fuel* 2014;117:697-703.
- [108] Bahmanyar AR, Karami A. Power system voltage stability monitoring using artificial neural networks with a reduced set of inputs. *Electrical Power and Energy Systems* 2014;58:246-56.
- [109] Sumathi S, Bansilal. Artificial Neural Network for coordinated control of STATCOM, generator excitation and tap changing transformer. *Electrical Power and Energy Systems* 2015;64:536-41.
- [110] Taghavifar H, Mardani A. Applying a supervised ANN (artificial neural network) approach to the prognostication of driven wheel energy efficiency indices. *Energy* 2014;68:651-57.
- [111] Rodger JA. A fuzzy nearest neighbor neural network statistical model for predicting demand for natural gas and energy cost savings in public buildings. *Expert Systems with Applications* 2014;41:1813-29.
- [112] Mena R, Rodríguez F, Castilla M, Arahal MR. A prediction model based on neural networks for the energy consumption of a bioclimatic building. *Energy and Buildings* 2014;82:142-55.
- [113] Mavromatidis G, Acha S, Shah N. Diagnostic tools of energy performance for supermarkets using Artificial Neural Network algorithms. *Energy and Buildings* 2013;62:304-14.
- [114] Kromer S. Efficiency valuation: how to “plan, play and settle” energy efficiency projects', *Strategic planning for energy and the environment* 2007;27:69-78.
- [115] Cybenko G. Approximations by superpositions of sigmoidal functions. *Mathematics of Control, Signals, and Systems* 1989;2(4):303-314.

- [116] Saltelli A. Making best use of model evaluations to compute sensitivity indices. *Computer Physics Communications* 2002;145:280-97.
- [117] Castellano G, Fanelli AM. Variable selection using neural-network models. *Neurocomputing* 2000;31:1-13.
- [118] Rumelhart DE, Hinton GE, Williams RJ. Learning internal representations by error propagation. *Parallel distributed processing: explorations in the microstructure of cognition* 1986; 1(1). Cambridge, MA: MIT Press, 318-62.
- [119] Hernández L. Predicción y optimización de emisiones y consumo mediante redes neuronales en motores Diesel. España, Ed. Reverté, 2010.
- [120] Thermoflow Inc., 2 Willow Street, Suite 100, Southborough, MA 01745-1020, USA.
- [121] Goodarzi M, Deshpande S, Murugesan V, Katti SB, Prabhakar YS. Is Feature Selection essential for ANN modeling? *QSAR & Combinatorial Science* 2009;28:1487-99.

Abreviaciones y símbolos

BP	Baja presión
ESE	Empresa de servicios energéticos
FS	Selección de características (Feature Selection)
MAE	Medida de ahorro energético Error absoluto medio (Mean Absolute Error)
MP	Media presión
ORC	Ciclo orgánico de Rankine
PCI	Poder calorífico inferior
PMC	Perceptrón multicapa
R	coeficiente de Pearson de correlación del producto-momento
REE	Rendimiento eléctrico equivalente
RMSE	Error cuadrático medio (Root Mean Square Error)
RNA	Redes neuronales artificiales
SCD	Sistema de control distribuido
TET	Temperatura de los gases de combustión a la entrada de la turbina de gas (Turbine Entry Temperature)
TG	Turbina de gas
HRSG	Caldera de recuperación (Heat Recovery Steam Generator)
VIGV	Álabes de admisión del aire a la turbina de gas (Variable Inlet Guide Vanes)

